



Bruno Miguel Fernandes Ribeiro

Licenciatura em Ciências da Engenharia Biomédica

SYPEC: Desenvolvimento de novos algoritmos de Classificação e Correção Postural

Dissertação para obtenção do Grau de Mestre em
Engenharia Biomédica

Orientador : Doutor Pedro Vieira, Professor Auxiliar, FCT-UNL

Co-orientador : Mestre Leonardo Martins, Investigador UNI-
NOVA, FCT-UNL

Júri:

Presidente: Doutora Carla Maria Quintão Pereira

Arguente: Doutora Isabel Maria Nascimento Lopes Nunes

Vogal: Doutor Pedro Manuel Cardoso Vieira



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Novembro, 2014

SYPEC: Desenvolvimento de novos algoritmos de Classificação e Correção Postural

Copyright © Bruno Miguel Fernandes Ribeiro, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

*Ao meu pai que me moldou na pessoa que sou hoje.
À minha família e amigos que me ajudaram nesta jornada.*

Agradecimentos

Gostaria de agradecer a todos os que contribuíram nas mais variadas formas, para a realização e término da presente dissertação.

À professora Adelaide de Jesus pela concepção da ideia do projecto SYPEC e à professora Cláudia Quaresma pela sua ajuda no desenvolvimento do mesmo.

Aos meu orientadores, Professor Pedro Vieira e Leonardo Martins pela orientação e apoio prestado durante a realização desta dissertação, pela disponibilidade mostrada na resolução de todos os problemas que apareceram durante este percurso e, finalmente, por permitirem que eu fizesse parte deste projecto.

Ao meu colega de trabalho neste projecto, Hugo Pereira, por todo o apoio prestado durante este projecto, especialmente na fase inicial e no processo de aquisição de dados.

Além das pessoas que contribuíram directamente para o sucesso deste trabalho gostaria também de agradecer à minha família que me acompanhou durante toda a minha vida apoiando-me sempre que necessário.

Não podia também deixar de agradecer aos meus colegas de curso que ao longo destes cinco anos se tornaram para mim numa segunda família, não é preciso dizer nomes, pois eles sabem quem são.

A todos os acima mencionados o meu sincero obrigado, pois sem eles não teria conseguido chegar a este ponto.

Resumo

A posição sentado é frequentemente adotada pela maioria das pessoas nas atividades profissionais, domésticas e de lazer. Porém, a manutenção prolongada dessa posição leva geralmente à adoção de posturas incorretas que sobrecarregam as estruturas musculoesqueléticas da coluna, dando origem ao aparecimento de dor e lesões, com especial incidência na região lombar.

A presente dissertação de mestrado insere-se no desenvolvimento de novos algoritmos de classificação e correção postural no âmbito do projeto SYPEC (*SYstem for Posture Evaluation and Correction*).

Deu-se continuidade ao trabalho já desenvolvido fazendo uma otimização através da utilização de árvores de decisão e redes neurais, separando os sujeitos em relação à sua altura, peso e/ou género com recurso aos dados pré-processamento.

Verificou-se ainda a influência do ângulo lateral no comportamento do classificador existente enquanto o utilizador altera a sua posição, motivando a utilização de lógica difusa (fuzzy logic) no novo classificador desenvolvido, para poder lidar com posturas intermédias que não estavam previamente definidas.

Redesenhou-se o processo de classificação de modo a juntar aos classificadores por redes neurais a lógica difusa para criar um novo algoritmo neuro-fuzzy. Foram introduzidos novos atuadores baseados na lógica difusa para a correção postural.

Palavras-chave: Postura de sentado; Classificação Postural; Correção Postural; Redes Neurais; Lógica Fuzzy.

Abstract

The sitting position is frequently adopted by a majority of people in their professional, domestic and leisure activities. However, prolonged maintenance of this position usually leads to the adoption of incorrect postures overloading the musculoskeletal structures of the spine, originating pain and lesions, specially in the lumbar region.

The present master's dissertation is incorporated in the development of new classification and correction algorithms inserted in the SYPEC project (SYstem for Posture Evaluation and Correction).

Starting from previously developed work, the existing classification algorithms based on neural networks were optimized by using classification trees to split the subjects regarding their height, weight and/or gender using the pre-process data.

The influence of the lateral angle in the classification algorithm behaviour was investigated while the user changes its position. This motivated the implementation of fuzzy logic in the newly developed classifier to be able to handle intermediate postures which were not previously defined.

The classification process was redesigned to fuse the artificial neural networks with fuzzy logic, to create a new neuro-fuzzy algorithm. New actuators based on fuzzy logic were developed for the new posture correction algorithm.

Keywords: Sitting posture; Postural classification; Postural correction; Neural networks; Fuzzy logic.

Conteúdo

Agradecimentos	vii
Resumo	ix
Abstract	xi
Lista de Figuras	xv
Lista de Tabelas	xvii
Abreviaturas	xix
1 Introdução	1
1.1 Enquadramento	1
1.2 Objetivos	2
1.3 Estrutura da Dissertação	3
2 Revisão da literatura	5
2.1 Postura Sentado	5
2.2 Detecção e classificação da postura	6
2.3 Correção automática	7
2.4 Classificadores	9
2.4.1 Redes neuronais	9
2.4.2 Árvores de decisão	10
2.4.3 Fuzzy Logic	10
2.5 Actuadores Fuzzy	12
3 Protótipo SYPEC	13
3.1 Novo protótipo	14
3.2 Aquisição de Dados	15

4	Classificação Postural - Implementação e Avaliação	19
4.1	Algoritmos Existentes	19
4.2	Otimização do Classificador	20
4.3	Impacto do Ângulo no Classificador	23
4.4	Integração de Lógica Fuzzy no Classificador	28
5	Correção	31
5.1	Pontos de atuação	32
5.2	Sistema de Controlo	33
6	Conclusões e trabalho futuro	35
	Bibliografia	37
A	Anexo I - Participantes nas Experiências	41
A.1	Participantes na recolha de dados para calibração do sistema SYPEC . . .	41
A.2	Participantes na experiência da avaliação da influência do ângulo no clas- sificador	44
B	Anexo II - Análises dos Dados Adquiridos	45
B.1	Diagramas caixa-de-bigodes	45
B.2	Gráficos - Centro de Pressão	48
C	Anexo III - Matrizes de Confusão	51

Lista de Figuras

1.1	Diagrama representativo do sistema SYPEC.	2
2.1	Sistema de avaliação e correcção postural onde se observam os 7 transdutores de pressão [2].	7
2.2	Agente responsável pela transmissão do feedback (esquerda). Cadeira equipada com sensores de força (direita). [19].	8
2.3	Rede neuronal de 3 camadas. São visíveis as camadas de entrada, interna e de saída [23].	9
2.4	Raciocínio <i>fuzzy</i> para o caso de múltiplas regras com antecedentes múltiplos [31].	11
3.1	Primeiro protótipo do sistema SYPEC.	13
3.2	(a) Esquema das novas bolsas usadas no assento e nas costas da cadeira e as suas medidas (b) Posição das bolsas na cadeira [40].	14
3.3	(a) Módulo de controlo (b) Módulos para as bolsas das costas (c) Módulos para as bolsas do assento.	15
3.4	Computador de placa única Raspberry Pi.	15
3.5	Posturas presentes neste protocolo: (P1) Direito, (P2) Inclinado para a frente, (P3) Inclinado para trás, (P4) Inclinado para trás, apenas com apoio dorsal, (P5) Inclinado para a direita, (P6) Inclinado para a esquerda, (P7) Perna esquerda cruzada, (P8) Perna direita cruzada, inclinado para a esquerda, (P9) Perna esquerda cruzada, (P10) Perna esquerda cruzada, inclinado para a direita, (P11)Perna esquerda sobre a direita, (P12) Perna direita sobre a esquerda.	16
3.6	Posição curvado [4].	17
3.7	Dados processados da aquisição de valores de pressão para os 8 sensores. (Sujeito 5)	17

4.1	Performance do classificador 3-30 treinado e testado com os sujeitos selecionados (Tabela 4.1).	21
4.2	Fluxograma da classificação otimizada.	23
4.3	Pontos de alteração de comportamento do classificador. (a) Primeira alteração; (b) Estabilização do classificador.	24
4.4	Aquisição de dados. Valores de pressão (linhas coloridas) e postura dada pelo classificador (a preto)	25
4.5	Aplicação para medir o ângulo lateral da inclinação do tronco do sujeito. .	26
4.6	Fluxograma de classificação com o bloco fuzzy.	28
4.7	Diagrama do bloco fuzzy.	28
4.8	Função de pertença para o centro de pressão. Componente x horizontal(assento).	29
4.9	Função de pertença para o tempo numa posição incorreta.	29
4.10	Função de pertença para a saída do classificador.	29
5.1	Fluxograma do processo de correção de postura [47].	32
5.2	Pontos de atuação para cada uma das posturas. A tabela de cima representa as costas da cadeira, e a debaixo o assento.	33
5.3	Fluxograma do funcionamento do sistema de correção.	33
B.1	Diagrama de caixa de bigodes das posições 1 e 2.	45
B.2	Diagrama de caixa de bigodes das posições 3 a 8.	46
B.3	Diagrama de caixa de bigodes das posições 9 a 12.	47
B.4	Centros de pressão das posições 1 a 4.	48
B.5	Centros de pressão das posições 5 a 8.	49
B.6	Centros de pressão das posições 9 a 12.	50
C.1	Matriz de confusão - 1 camadas - 40 neurónios - P1 a P6.	51
C.2	Matriz de confusão - 3 camadas - 30 neurónios.	52
C.3	Matriz de confusão - 2 camadas - 30 neurónios - Masculino.	52
C.4	Matriz de confusão - 3 camadas - 30 neurónios - Masculino.	53
C.5	Matriz de confusão - 2 camadas - 30 neurónios - Feminino.	53
C.6	Matriz de confusão - 3 camadas - 30 neurónios - Feminino.	54
C.7	Matriz de confusão - 2 camadas - 30 neurónios - Altura abaixo.	54
C.8	Matriz de confusão - 3 camadas - 30 neurónios -Altura abaixo.	55
C.9	Matriz de confusão - 2 camadas - 30 neurónios - Altura acima.	55
C.10	Matriz de confusão - 3 camadas - 30 neurónios - Altura acima.	56
C.11	Matriz de confusão - 2 camadas - 30 neurónios - Peso abaixo.	56
C.12	Matriz de confusão - 3 camadas - 30 neurónios - Peso abaixo.	57
C.13	Matriz de confusão - 2 camadas - 30 neurónios - Peso acima.	57
C.14	Matriz de confusão - 3 camadas - 30 neurónios - Peso acima.	58

Lista de Tabelas

3.1	Dados dos participantes na experiência	15
4.1	Dados dos sujeitos analisados na experiência de otimização do classificador.	20
4.2	Performance das árvores de decisão - Dados pré-processados vs. pós-processados	21
4.3	Performance das árvores de decisão. Dados separados pela mediana. (a) Peso; (b) Altura.	22
4.4	Performance das redes neurais para cada um dos fatores analisados: gênero, peso e altura.	22
4.5	Sumário da performance resultante da otimização dos classificadores. . .	23
4.6	Dados dos sujeitos utilizados na construção da rede neuronal	23
4.7	Dados dos participantes na experiência: impacto do ângulo no classificador.	24
4.8	Ângulos à qual o comportamento do classificador se alterava.	26
4.9	Coeficiente de correlação intraclasse.	26
4.10	Resultados do teste de Kolmogorov-Smirnov.	27
4.11	Regras do classificador.	30

Abreviaturas

ANFIS Adaptative Networks-based Fuzzy Inference Systems

BL Back Left

BR Back Right

CART Classification and Regression Trees

DL Down Left

DR Down Righth

ECG Electrocardiography

EEG Electroencephalography

FL Front Left

FR Front Right

ICC Intraclass Correlation Coefficient

MSE Mean Squared Error

UL Up Left

UR Up Right



Introdução

1.1 Enquadramento

A nossa sociedade tem vindo a tornar-se cada vez mais sedentária, sendo a posição sentado a mais adotada tanto a nível profissional e escolar, como a nível de lazer. Uma grande parte da população dos países desenvolvidos passa a maior parte do seu dia sentada. Esta é a posição de eleição uma vez que requer um menor esforço por parte dos músculos do que permanecer em pé e devido ao facto das profissões continuarem a exigir, cada vez mais, um maior tempo nessa posição.

No entanto permanecer sentado durante um longo período de tempo traz desvantagens e consequências a longo prazo, podendo provocar lesões músculo-esqueléticas, nomeadamente, ao nível da coluna vertebral [1]. Por esta razão, de modo a prevenir problema de saúde relacionados com a adoção da postura de sentado durante longos períodos de tempo, é recomendado não permanecer demasiado tempo nesta posição e adotar uma postura o mais correta possível que permita desempenhar as funções necessárias com o maior conforto possível fazendo, sempre que possível, pausas. [2, 3].

É com vista a endereçar esses problemas que o projeto SYPEC (Sistema de Avaliação e Correção Postural) tem sido desenvolvido nos últimos dois anos entre a Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa e a NGNS – ingenious solutions, Lda. com o apoio do Fundo Europeu de Desenvolvimento Regional (FEDER), através do Quadro de Referência Estratégico Nacional (QREN) e do Programa Operacional Regional de Lisboa (PORLisboa). Este tem em vista o desenvolvimento de uma cadeira com capacidade de avaliar e ajustar de uma forma automática a posição sentado. Este sistema pretende exercer um papel preventivo e educacional junto da população, possibilitando a mudança de hábitos inadequados, nomeadamente para utilizadores de computador,

passageiros de longo curso e/ou outras situações em que o número de horas passadas na posição de sentado possa ser crítico em termos de saúde. O projeto SYPEC, quando concluído, permitirá:

1. Monitorização e avaliação postural de um utilizador na posição de sentado;
2. Correção automática da postura através de alterações na conformação e rigidez do assento e costas da cadeira;
3. Resposta personalizada em termos de apoios lombares e cervicais;
4. Indução da correção de posturas incorretas tendo o utilizador um papel passivo no processo. Na sua globalidade o projeto SYPEC assenta em três princípios base: mapeamento das pressões do assento e das costas da cadeira, classificação postural e correção postural, como esquematizado na figura 1.1.



Figura 1.1: Diagrama representativo do sistema SYPEC.

1.2 Objetivos

Durante o desenvolvimento deste trabalho pretendem-se atingir os seguintes objetivos:

1. Otimização do classificador postural baseado em redes neurais desenvolvido por Santos [4] num trabalho anterior;
2. Implementação de novos Algoritmos de Classificação e Correção Postural baseados em lógica fuzzy, de modo a estender os algoritmos pré-existentes;
3. Avaliação da performance dos Algoritmos de Classificação Postural no novo protótipo SYPEC.

1.3 Estrutura da Dissertação

A presente dissertação está estruturada em seis capítulos, que serão descritos de seguida.

Neste primeiro capítulo é feita uma breve introdução ao tema em estudo, nomeadamente à problemática da posição de sentado, são referidos os objetivos a alcançar e a estrutura da presente Dissertação.

O capítulo 2 consiste na revisão da literatura do tema, abordando a temática da postura sentado. Fala-se também dos trabalhos desenvolvidos na área de deteção e avaliação postural. São ainda abordados os classificadores e atuadores fuzzy.

No capítulo 3 fala-se do início do projeto SYPEC, mais especificamente do primeiro protótipo. É posteriormente feita uma descrição do novo protótipo, havendo um foco nas novas características e de que forma colmatam as falhas do anterior. Por fim é feita uma descrição do protocolo de aquisição de dados utilizado.

O Capítulo 4 inicia-se com uma descrição dos classificadores utilizados no decorrer deste projeto e um breve resumo do estado dos classificadores antes do início deste trabalho. De seguida fala do trabalho desenvolvido na área da classificação, nomeadamente, do estudo do impacto do sujeito no processo de classificação, da otimização deste em função das características antropométricas do sujeito, e por fim da integração de lógica fuzzy no processo.

O capítulo 5 foca-se no processo de correção. É feita uma breve descrição dos primeiros algoritmos desenvolvidos. É feita análise dos pontos de atuação do processo de correção para cada postura, seguida da descrição do sistema de controlo e das suas características.

No Capítulo 6 são referidas as conclusões retiradas do trabalho efetuado, bem como apresentadas algumas sugestões do que ainda pode ser feito.



Revisão da literatura

A adoção de posturas incorretas na posição de sentado assim como os longos períodos de tempo em que estas são mantidas, podem provocar o desenvolvimento de patologias ao nível da coluna. Devido a este facto inúmeros trabalhos foram desenvolvidos na área da classificação e deteção de más posturas.

Além duma revisão da literatura nesta área, é também incluída neste capítulo uma breve revisão da literatura sobre os classificadores utilizados neste trabalho para a classificação postural.

2.1 Postura Sentado

A postura convencional de sentado foi definida como manter a face posterior do tronco encostada às costas da cadeira, com apoio lombar e flexão das coxas a 90° [5]. Atualmente, apesar de se perceber que existem posturas que devem ser adotadas em detrimento de outras e de haver grande aceitação clínica dos aspetos que influenciam a classificação de uma determinada postura em boa ou má, existe pouca base quantitativa que permita definir o ideal de postura na posição de sentado [6]. Subsiste a crença que essa avaliação deve ter por base as curvaturas da coluna vertebral que tem vindo a ser consubstanciada através de vários trabalhos de investigação [6, 7].

Define-se postura adequada como o estado de equilíbrio entre estruturas musculoesqueléticas que previne o aparecimento de lesões ou a sua deformação progressiva, e a sua adoção deve prevenir movimentos compensatórios e distribuir uniformemente as cargas na coluna vertebral [6, 7].

A adoção de posturas incorretas altera a atividade muscular e desencadeia mecanismos que põem em risco a integridade do sistema musculoesquelético da coluna vertebral.

Neste sentido a posição que apresenta menor impacto para as estruturas osteomioarticulares e que tem sido referenciada no meio clínico como a posição de sentado ideal é posição lordótica; nesta as curvaturas da coluna vertebral são mantidas e para além de diminuir a compressão e degeneração dos discos intervertebrais permite que se realizem movimentos ao nível dos membros inferiores que promovem o relaxamento muscular [7].

Para além da postura adotada existem outros aspetos a analisar que determinam o seu risco para a saúde, nomeadamente, o tempo de permanência e os aspetos ergonómicos da superfície na qual se está sentado [7]. A norma *ISO 11226 - Ergonomics — Evaluation of static working postures* [8] recomenda os limites aceitáveis de uma boa posição estática no trabalho, tendo em conta os ângulos tomados pelo corpo e o tempo de permanência numa dada posição.

A razão pela qual é tão importante que haja mobilidade ao longo do dia deve-se ao facto da coluna vertebral, a partir dos 10 anos, perder a capacidade de captar nutrientes e de eliminar resíduos. A partir desta idade este processo é efetuado através de trocas passivas realizadas pelo fluxo de fluído que é induzida pelo movimento [9, 10, 11]. É por esta razão que não se deve manter a mesma posição durante longos períodos de tempo, mas sim ir alternando entre posições, principalmente a posição de direito, inclinado para a frente e recostado para trás, que são as menos prejudiciais à saúde e que sujeitam a coluna a uma menor pressão [12].

Para a adoção de posturas mais corretas, muito tem contribuído as evoluções ergonómicas das cadeiras. Estas permitem, em muitos dos casos, adaptar a cadeira à estrutura e fisionomia de um indivíduo, influenciam a posição a adotar e facilitam a realização de pequenos movimentos de descompressão [7].

Mais recentemente inúmeros trabalhos têm vindo a ser desenvolvidos no desenvolvimento de cadeiras com detecção e classificação postural automatizada (Secção 2.2).

2.2 Detecção e classificação da postura

Tan et al. [13] e Slivovsky e Tan [14] estudaram o uso de uma cadeira inteligente para interações humano-computador, através da identificação da postura do utilizador na posição sentado. Equiparam uma cadeira de escritório com duas matrizes Body Pressure Measurement System (BPMS) da Tekscan® (Tekscan, 1997) de modo a obter os mapas de pressão da cadeira. Estas matrizes são compostas por 2016 transdutores de pressão para superfícies, cada uma, e foram colocadas no assento e costas da cadeira. Usando um algoritmo de reconhecimento de padrões em tempo real, centrado na Análise de Componentes Principais e classificação por Nearest Neighbour, treinaram o sistema para a classificação de 14 diferentes posições estáticas. Com este método atingiram uma eficácia de 96% e 76% na identificação postural quando testado em sujeitos familiarizados e não familiarizados com o sistema, respetivamente.

Outros estudos, que envolviam a obtenção dos mapas de pressão da posição sentado,

utilizaram uma cadeira e um sistema sensorial igual ao descrito anteriormente. Mota e Picard [15] relacionaram as posturas adoptadas por crianças na posição sentado com o seu nível de interesse enquanto executavam uma tarefa de aprendizagem num computador. Zhu et al. [16] estudaram diferentes algoritmos de classificação para avaliar a performance de cada um deles quando aplicados à identificação de posturas na posição sentado. Andreoni et al. [17] combinaram o uso das matrizes BPMS com um sistema óptico de captura de movimento para caracterizarem parâmetros específicos da postura dos condutores de viaturas automóveis.

Mais tarde, Mutlu et al. [18] motivados pela complexidade do processamento do elevado número de transdutores presentes nas matrizes BPMS, estudaram quais as distribuições, para 31 e 19 transdutores, que permitiriam obter resultados semelhantes às matrizes usadas em trabalhos anteriores. Calcularam quais os subconjuntos, de 31 e 19 transdutores, que atingiram a melhor performance junto do classificador de postura. Os seus métodos atingiram uma eficácia de 87% e 78% para 31 e 19 sensores, respetivamente, num conjunto de treino de 10 posturas estáticas da posição sentado.

2.3 Correção automática

Zheng e Morrell [2] desenvolveram um sistema de avaliação e correção postural automática, composto por 7 transdutores de pressão (Fig. 2.1) e 6 actuadores vibrotácteis. Definiram as tuberosidades isquiais, a região posterior da coxa, a região lombar da coluna vertebral e as omoplatas, como sendo os locais mais relevantes para a colocação dos transdutores de pressão para classificação postural. Ao contrário de Mutlu et al. [18], que usou uma abordagem matemática para a distribuição dos transdutores, Zheng e Morrell [2] utilizaram uma abordagem anatómica.




Figura 2.1: Sistema de avaliação e correção postural onde se observam os 7 transdutores de pressão [2].

O algoritmo de detecção compara a informação recebida em cada transdutor com valores de referência específicos do mesmo transdutor. Cada posição é caracterizada por

um vetor com valores de referência, onde cada valor do vetor corresponde a um único transdutor. Fazendo a média do quadrado do erro (MSE) entre a informação dos transdutores e dos valores de referência, a posição que obtiver o menor erro é a assumida pelo sistema.

Os atuadores vibrotácteis encorajam o sujeito a alterar a sua posição e atuam especificamente em função das alterações necessárias para corrigir a postura. A sua intensidade é dependente do valor absoluto do MSE. O sistema atingiu uma eficácia de 86.4% quando distinguia entre 10 posições estáticas e 93.8% para 4 posições estáticas.

Daian et al. [19] colocaram sensores de força numa cadeira, o sensor no assento indicava se alguém estava sentado, e o sensor nas costas verificava se a postura era correta. A informação dos sensores era processada por computador sendo os valores recebidos comparados com patamares determinados experimentalmente.

O sistema tinha uma tolerância de 20 segundos para posturas incorretas, após 20 e 40 minutos de uso o utilizador era informado para fazer uma curta pausa, e uma longa pausa após 60 minutos.




Figura 2.2: Agente responsável pela transmissão do feedback (esquerda). Cadeira equipada com sensores de força (direita). [19].

O feedback vem de um agente colocado na secretária e ligado ao computador (Fig. 2.2), este move-se e tem capacidade de enviar feedback audível.

Os movimentos são consistentes com o áudio, o agente vira as suas costas quando uma postura inadequada é detetada e está na direção do utilizador a quando uma postura correta é tomada pelo utilizador, faz ainda movimentos rápidos para a direita e para a esquerda quando em modo de exercício. A parte áudio consiste em pequenas mensagens adequadas à situação e ações recomendadas.

Outra alternativa para manter uma posição adequada enquanto se trabalha é a instalação de *software* criado para esse efeito. Os mais conhecidos são o WorkPace Wellnomics [20] que foi criado com o intuito de educar os utilizadores sobre fadiga muscular e recuperação, este recomenda exercícios regularmente e mostra alertas quando é necessário que seja feita uma pausa. Monitoriza ainda a intensidade do uso do computador e oferece *feedback* ao utilizador.

Outro *software* é o RSI-Shield, que é altamente configurável e além de providenciar pausas "inteligentes" e exercícios oferece também algumas medidas de prevenção. O programa grava operações feitas com frequência que podem posteriormente ser repetidas

automaticamente com o intuito de diminuir o uso do rato e teclado. No entanto o desenvolvimento deste programa foi descontinuado [21].

2.4 Classificadores

2.4.1 Redes neuronais

As redes neuronais foram inspiradas no funcionamento do sistema nervoso central. Adquirem o conhecimento a partir do ambiente envolvente através de processos de aprendizagem e as ligações entre os neurónios, conhecidas como pesos sinápticos, são usados para guardar conhecimento.

Uma rede neuronal é, tipicamente, formada por três tipos de neurónios. Estes podem ser neurónios da camada de entrada, que têm como função introduzir os dados na rede, neurónios das camadas internas e os neurónios da camada de saída que geram o resultado (Fig. 2.3). A cada neurónio da camada de saída é normal atribuir uma classe e a função da rede é conseguir, na presença de um determinado exemplo, associar a saída correspondente à classe a que esse exemplo pertence [22].




Figura 2.3: Rede neuronal de 3 camadas. São visíveis as camadas de entrada, interna e de saída [23].

Os exemplos inseridos no conjunto de treino são introduzidos na rede e é calculada a diferença entre a saída obtida e a desejada. Esse valor de erro é propagado para a camada de entrada (método de retropropagação) e é efetuado um ajuste dos valores dos pesos e das *biases* dos neurónios das várias camadas por forma a diminuir o erro obtido. Este é o método de aprendizagem mais conhecido, no entanto existem métodos alternativos [22].

Uma das primeiras aplicações de redes neuronais à medicina clínica foi o desenvolvimento de um classificador para detetar enfartes do miocárdio [24]. Hart e Wyatt [25] treinaram uma rede neuronal em 174 pacientes que apresentavam dor no peito e que os classificava em: alto risco cardíaco, baixo risco cardíaco e não cardíaco.

Outras aplicações de diagnóstico clínico usando redes neuronais foram desenvolvidas. Nomeadamente, um sistema para a análise de imagens radiológicas e classificação

de lesões ósseas em benignas e malignas [24]. São também utilizadas para o estudo de sinais fisiológicos, nomeadamente ECG's e EEG's [24].

2.4.2 Árvores de decisão

Árvores de decisão são diagramas que possibilitam enumerar todas as possibilidades lógicas de uma sequência de decisões e ocorrências incorretas. Numa árvore de decisão cada nó representa uma decisão entre um número limitado de opções e cada folha uma classificação, atribuindo uma classe.

Os dois sistemas que são mais usados normalmente para gerar árvores de decisão são o C4.5 e o CART.

O algoritmo C4.5 é a extensão feita por Quillan ao seu algoritmo ID3 para gerar árvores de decisão [26]. Este algoritmo usa uma técnica chamada dividir e conquistar. Começa com todas as amostras de treino no primeiro nó da árvore. Um atributo é selecionado para partir estas amostras. Para cada valor do atributo um ramo é criado e o grupo de amostras que têm o valor especificado pelo novo ramo são movidas para o recém criado nó. O algoritmo é aplicado recursivamente a cada novo nó até que todas as amostras num nó sejam da mesma classe. Cada caminho para uma folha representa uma regra de classificação. É de notar que a decisão crucial num algoritmo deste género é a escolha do atributo a usar.

A metodologia Árvores de Classificação e Regressão(CART) foi desenvolvida nos anos 80 por Breiman et al. [27]. É um método para construir árvores de decisão binárias ou, por outras palavras, CART apenas faz perguntas de resposta sim ou não [28]. Os autores deste método defendem que divisões binárias são preferíveis uma vez que fragmentam os dados mais lentamente e são permitidas partições várias ao mesmo atributo e, se selecionado, irá eventualmente gerar quantas partições para um atributo forem necessárias.

Esta metodologia consiste em três partes:

1. Construção da árvore máxima;
2. Poda da árvore;
3. Escolha do tamanho de árvore certo.

O objetivo não é produzir uma árvore, mas uma sequência de árvores podadas que são candidatas a ser a árvore ótima.

2.4.3 Fuzzy Logic

A *fuzzy logic* (lógica difusa) é uma extensão da lógica booleana que admite valores entre o Verdadeiro(1) e o Falso(0), por exemplo, o Talvez(0,5) [29]. Esta forma de abordar o problema permite que estados indeterminados possam ser tratados por dispositivos de

controlo. Na última década foi aplicada a várias áreas variando desde o controlo de processos industriais ao diagnóstico médico [30].

Para obter a saída de um sistema com *fuzzy logic*, a resposta a cada regra é pesada de acordo com o grau de pertença das suas entradas, calculando-se então o centróide das respostas [30]. Podemos ver na figura 2.4 um exemplo da aplicação destes conceitos a uma situação com múltiplas regras e múltiplos antecedentes. Temos as seguintes premissas: x é A' e y é B' (facto), se x é A_1 e y é B_1 então z é C_1 (regra 1), se x é A_2 e y é B_2 então z é C_2 (regra 2) e z é C' (conclusão). Onde C_1 e C_2 são os conjuntos inferidos a partir das regras 1 e 2 respetivamente, e C' é o conjunto de saída [31].




Figura 2.4: Raciocínio *fuzzy* para o caso de múltiplas regras com antecedentes múltiplos [31].

Suryanarayanan et al. [32] desenvolveram um sistema de diagnóstico baseado em lógica difusa capaz de classificar pacientes com Disfagia Orofaríngea em quatro categorias de risco de aspiração: severo, moderado, leve e não existente. Obtiveram medidas não invasivas da aceleração e pressão ao engolir em 22 pacientes. Em 18 destes a saída do classificador estava de acordo com a opinião do médico.

Ao acoplarmos a teoria das redes neuronais, nomeadamente a aprendizagem por retropropagação, com a lógica difusa obtemos sistemas adaptativos de inferência fuzzy baseados em redes (ANFIS) [31]. Estes sistemas são então capazes de se adaptar às suas condições de funcionamento, podendo se aplicados tanto à área da classificação de dados, como à filtragem de sinais [31].

Ranjan et al. [33] usaram lógica fuzzy e neuro-fuzzy para determinar o tipo de bio-material a utilizar na operação a pacientes com Incontinência de esforço (SUI). Desenvolveram ainda, usando as mesmas ferramentas, uma aplicação para prever o tempo de recuperação de pacientes em fisioterapia para enfartes, paraplegia e tetraplegia, etc [33].

Balbinot e Favieiro [34] desenvolveram um sistema que usa os sinais mio-elétricos adquiridos usando eléctrodos de superfície para caracterizar certos movimentos do braço.

Isto foi conseguido desenvolvendo um algoritmo de reconhecimento de padrões baseado em neuro-fuzzy. Este algoritmo tinha como entrada o sinal mio-elétrico pré-processado e como saída o movimento efetuado. A eficácia média obtida por este sistema para 7 movimentos distintos foi 86%.

2.5 Actuadores Fuzzy

Em estudos ligados à medicina e à bioinformática a incerteza nas medições é uma constante. A lógica fuzzy tem esse facto em conta e a sua teoria pode ser considerada adequada para lidar com as imprecisões intrínsecos aos problemas da biomedicina. A lógica fuzzy permite tornar preciso o impreciso [35].

Juang e Chang [36] criaram um classificador de postura corporal baseado em sistemas neuro-fuzzy. Este classificava quatro posições principais: em pé, abaixado, sentado e deitado. Esta classificação era obtida pegando na imagem obtida de uma câmara, num ponto fixo, fazendo a transformada discreta de fourier das projeções verticais e horizontais. Eram posteriormente usados os coeficientes da transformada e o rácio comprimento-largura da silhueta como entradas do classificador. O sistema era capaz de assim detetar quedas, e emitir alarmes caso a pessoa não se levantasse num período de tempo pré-determinado.

Gopalai et al. [37] desenvolveram um sistema para medir o controlo postural com feedback em tempo real. Utilizaram um sistema de inferência fuzzy (FIS) baseado em medidas do ângulo do tronco no eixo Antero-posterior. O aviso de que uma postura incorreta está a ser tomada é dado por atuadores vibrotácteis.

Leite et al. [38] desenvolveram um modelo fuzzy para a monitorização e classificação dos sinais vitais de pacientes hospitalizados capaz de enviar alertas de acordo com o pré-diagnóstico feito de modo a auxiliar o diagnóstico médico.

Protótipo SYPEC

No âmbito da sua Dissertação de Mestrado Lucena [39] desenvolveu o primeiro protótipo do sistema SYPEC (Fig. 3.1). Numa cadeira de escritório convencional foram colocadas 8 almofadas de ar (4 no assento e 4 nas costas), cada uma ligada a um circuito de ar independente composto por um compressor de ar, uma electroválvula e um transdutor de pressão. Para controlar o ar no interior de cada bolsa eram usados o compressor e a electroválvula que permitiam injetar ou retirar ar das bolsas alterando, desta forma, a rigidez e a conformação do assento e das costas da cadeira. O transdutor de pressão possibilita medir os valores de pressão do ar no interior da bolsa, sendo assim possível a elaboração dos mapas de pressão da cadeira. Esta estava ligada a um computador por USB [39], tendo sido, posteriormente, desenvolvida uma aplicação Android que permitia o seu controlo através de uma ligação Bluetooth [4].



Figura 3.1: Primeiro protótipo do sistema SYPEC.

3.1 Novo protótipo

O protótipo mencionado anteriormente tinha duas características que limitavam a sua performance. Em primeiro lugar, o facto de as bolsas terem sido produzidas manualmente [39] levou a que as bolsas tivessem tamanhos diferentes, o que provocou alguns problemas a nível da classificação postural. Em segundo lugar, o facto de o processo de retirar ar das bolsas ser feito por ação gravítica, com o abrir das electroválvulas, criou problemas no desenvolvimento dos algoritmos de correção de postura devido à incerteza associada à quantidade de ar que estava a ser retirada.

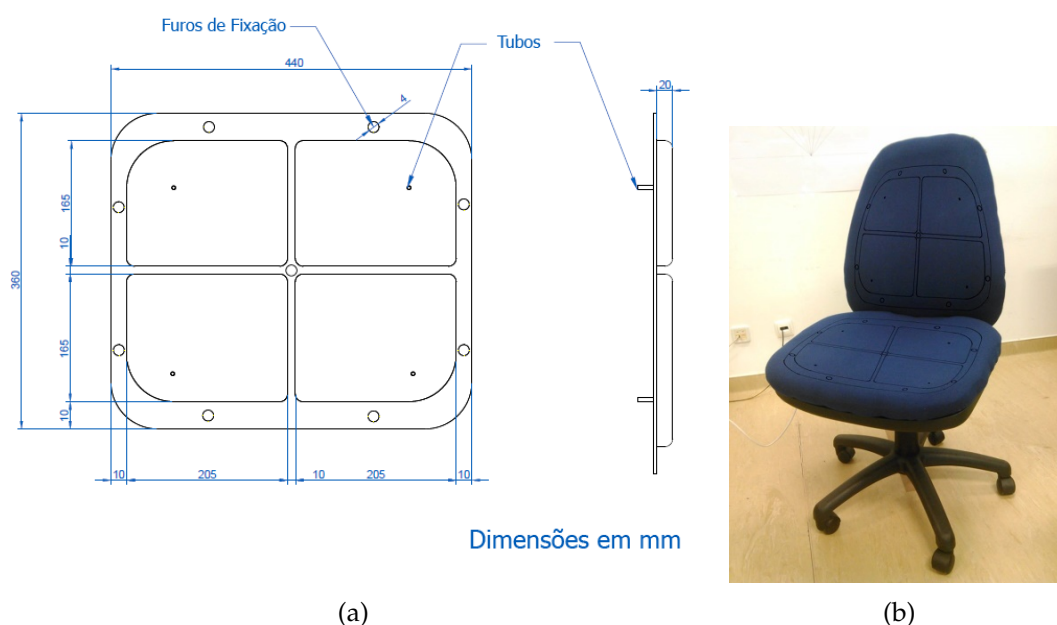


Figura 3.2: (a) Esquema das novas bolsas usadas no assento e nas costas da cadeira e as suas medidas (b) Posição das bolsas na cadeira [40].

As características mencionadas foram alteradas no segundo protótipo (Fig. 3.2b), montado pelo Mestre Hugo Pereira no decorrer da sua bolsa de investigação [41], com a introdução de bombas de vácuo para controlar a saída de ar (Fig. 3.3a) e com uso de bolsas de ar produzidas industrialmente (Fig. 3.2a). Além das mudanças para colmatar os problemas referidos adotou-se uma filosofia de construção modular em contraste com a centralização do protótipo anterior. Esta alteração visou facilitar a manutenção do protótipo, uma vez que em caso de avaria numa bolsa basta aceder à sua respetiva caixa de controlo (Fig. 3.3a). Podemos ver nas figuras 3.3b e 3.3c a integração dos módulos com a cadeira.

Ao contrário do protótipo inicial que operava a partir de um computador por ligação USB [39], ou recorrendo ao poder de processamento de um tablet [4]. De modo a caminhar em relação à autonomia do sistema, que é o objetivo final com vista à distribuição comercial, passou-se o controlo do sistema para um computador de placa única, o Raspberry Pi, que se pode ver na figura 3.4.




Figura 3.3: (a) Módulo de controlo (b) Módulos para as bolsas das costas (c) Módulos para as bolsas do assento.




Figura 3.4: Computador de placa única Raspberry Pi.

O novo protótipo, apesar de apresentar novos avanços em relação ao anterior, tal como foi mencionado anteriormente, tem ainda algumas coisas a melhorar, nomeadamente o ruído produzido pelo sistema pneumático que o torna demasiado ruidoso para ser usado em ambiente laboral. De modo a resolver este problema, no futuro, serão usados componentes menos ruidosos e será feito um melhor isolamento dos mesmos. O trabalho de desenvolvimento deste novo sistema foi enviado para as Jornadas Internacionais do Centro de Medicina de Reabilitação de Alcoitão.

3.2 Aquisição de Dados

De modo a calibrar o novo sistema desenvolvido foi necessário fazer uma nova aquisição de dados de pressão para cada uma das posturas a classificar. No total foram adquiridos dados de 72 pessoas, a sua média de idade peso e altura podem ser observados na tabela 3.1. Os seus dados individuais podem ser observados no anexo A.1.

Número de Sujeitos (M/F)	Idade (anos)	Peso (Kg)	Altura (cm)
72 (37/35)	26,6±9,3	67,7±12,7	170,8±9,4

Tabela 3.1: Dados dos participantes na experiência

Tal como no trabalho anterior [4] foi necessário definir o tempo de enchimento para as bolsas de modo a haver ar suficiente para ser detetada a pressão no seu interior. As novas bolsas têm todas exatamente o mesmo tamanho, por isso, em vez de se usarem



Figura 3.5: Posturas presentes neste protocolo: (P1) Direito, (P2) Inclinado para a frente, (P3) Inclinado para trás, (P4) Inclinado para trás, apenas com apoio dorsal, (P5) Inclinado para a direita, (P6) Inclinado para a esquerda, (P7) Perna esquerda cruzada, (P8) Perna direita cruzada, inclinado para a esquerda, (P9) Perna esquerda cruzada, (P10) Perna esquerda cruzada, inclinado para a direita, (P11) Perna esquerda sobre a direita, (P12) Perna direita sobre a esquerda.

tempos diferentes para cada bolsa [42], foi usado o valor de 5 segundos para todas. Este valor provou ser suficiente para produzir mapas de pressão para a classificação, mas não elevado o suficiente para produzir desconforto aos utilizadores.

Tal como no protocolo anterior [4] foi pedido aos sujeitos que retirassem todo o material que tivessem nos bolsos e que ajustassem a altura da cadeira de modo a que os seus joelhos fizessem um ângulo de 90° com a coxa.

Foram feitas aquisições para 12 posturas, que podemos ver na figura 3.5. A aquisição de dados consistiu em dois testes, o primeiro (Teste Dinâmico) envolvia a exibição de cada uma das 12 posturas, por ordem, sendo mostradas durante 20 segundos cada uma. O segundo (Teste Estático) consistia em exibir a mesma apresentação, mas com cada postura a ser mostrada duas vezes, e com a particularidade de após cada postura o sujeito se levantar, andar até uma marca no chão, e voltar-se a sentar.

As posturas foram escolhidas para representar as posições mais comuns em ambientes de escritório e foram baseadas em trabalhos anteriores [4]. O protocolo atual tem duas diferenças em relação anterior [4]. Em primeiro lugar a posição curvado (Fig. 3.6) foi retirada uma vez que era uma posição difícil de imitar e classificar, e sendo uma posição intermédia entre P1 e P2 a utilização de classificadores fuzzy resolvem os problemas que esta trazia. Em segundo lugar, foram adicionadas duas novas posturas, P11 - Perna esquerda sobre a direita e P12 - Perna direita sobre a esquerda, uma vez que são também posições adotadas, principalmente pelas mulheres, preferindo muitas vezes sobre a

perna cruzada mais comum (P7 e P9).



Figura 3.6: Posição curvado [4].

Da mesma forma que em trabalhos anteriores [4], nem todos os dados são utilizados, apenas se usa a zona estável, os dados das zonas de transição são descartados. O protótipo SYPEC tem uma frequência de amostragem de valores de pressão para os 8 sensores de 8 Hz. Utilizando o plugin de MATLAB® desenvolvido por Santos [4], com pequenas alterações, foram extraídos 100 pontos (correspondendo a 12,5 segundos dos 20 segundos adquiridos por posição). Estes 100 pontos foram posteriormente divididos em 5 médias de 20 pontos. E ainda normalizados ao intervalo $[-1, 1]$ de modo a serem usados como entradas nas redes neuronais (Fig. 3.7). Ou seja, no total, obtivemos 12960 pontos ($72 \text{ aquisições} * 12 \text{ posições} * 5 \text{ médias} * 3 \text{ repetições}$).

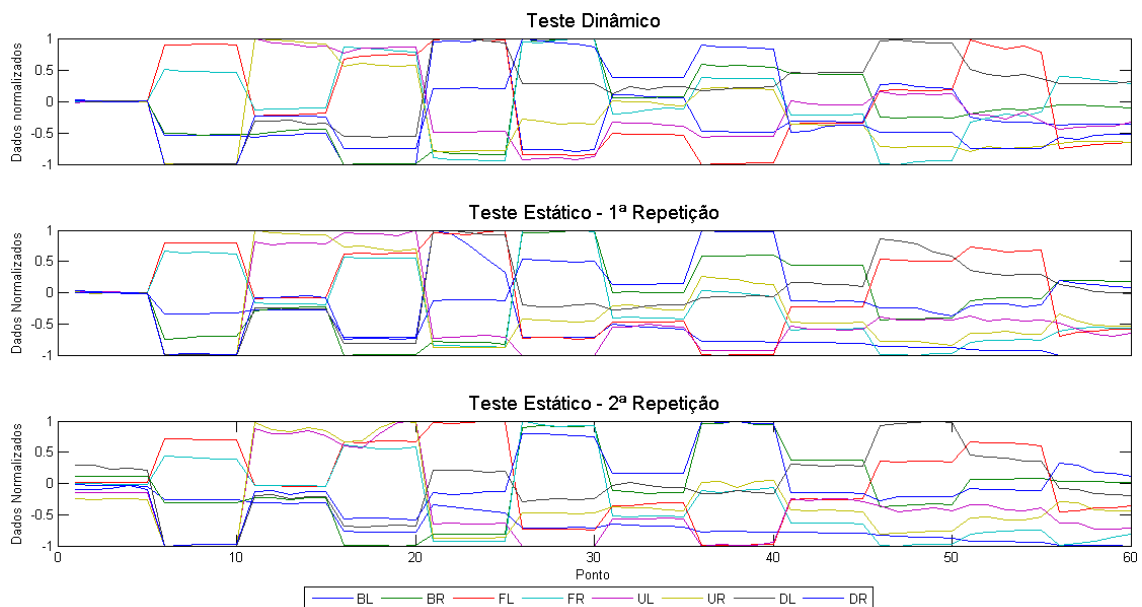


Figura 3.7: Dados processados da aquisição de valores de pressão para os 8 sensores. (Sujeito 5)

4

Classificação Postural - Implementação e Avaliação

4.1 Algoritmos Existentes

No âmbito do projeto SYPEC Santos [4] desenvolveu os algoritmos de classificação, baseado em dados previamente treinados. Estudou 11 posturas diferentes e realizou testes a 30 sujeitos.

Santos [4] desenvolveu dois classificadores, um baseado em redes neuronais e outro no Teorema de Bayes, o *Naive Bayes*. Testou vários parâmetros para as redes neuronais, tendo obtido os melhores resultados com o treino *Resilient Backpropagation*, que demonstrou um melhor desempenho em relação ao *Levenberg-Marquardt* e ao *Scaled Conjugate Gradient*. Verificou que ao usar menos camadas e 15 a 35 neurónios conseguia obter boas classificações, com maior rapidez e sem utilizar demasiada memória. Desta forma, identificou o treino com uma camada e 15 neurónios como a melhor opção. Obtendo uma classificação média de 75% para os 30 sujeitos. Para o Naive Bayes, usou dois tipos de distribuições, a normal e a *kernel*, obtendo uma classificação média de 70%.

Santos [4] concluiu que as redes neuronais permitiam obter uma informação mais completa em relação ao *Naive Bayes*, permitindo alterar diversos parâmetros, como o tipo de treino, número de camadas e número de neurónios. Como tal concluiu que se tratavam da melhor opção para este estudo, quando comparada com o *Naive Bayes*.

Com recurso a uma aplicação móvel e à adaptação das redes neuronais feita em trabalhos a decorrer em paralelo [42], foi possível identificar em tempo real a postura em

que o utilizador se encontrava. Martins et al. [43] verificaram em tempo real os resultados para 8 posturas, utilizando as redes neuronais, com bons resultados de classificação, 93.4%, mesmo para utilizadores que estavam a utilizar a cadeira pela primeira vez.

4.2 Otimização do Classificador

Como vimos anteriormente (Secção 3.2) os dados dos 8 sensores são normalizados ao intervalo $[-1; 1]$ antes de entrarem nos classificadores. O que se decidiu fazer foi analisar os dados pré-processados para verificar se estávamos a perder informação e também se seria possível otimizar o classificador, nomeadamente classificar o sujeito quanto ao seu género, altura ou peso verificámos se seria possível separar e baseado nesses fatores ter diferentes redes neuronais.

Para verificar esta hipótese, analisámos os dados de 50 pessoas (Tabela 4.1), 25 sujeitos de cada sexo, escolhidos aleatoriamente.

Número de Sujeitos (M/F)	Idade(anos)	Peso(Kg)	Altura(cm)
50 (25/25)	26,4±9,5	66,8±12,8	170,5±9,8

Tabela 4.1: Dados dos sujeitos analisados na experiência de otimização do classificador.

Na figura 4.1 podemos observar a performance do classificador criado recorrendo à *toolbox* do MATLAB®, *Neural Network Pattern Recognition ToolTM*. Treinado com o método *Resilient Backpropagation*, com 3 camadas de 30 neurónios, tendo 84,8% de acertos para a classificação postural. Facilmente verificamos que a zona envolvida no círculo (Fig. 4.1), dados de pessoas acima da média em termos antropométricos (média a traçado), tem uma taxa de classificações acertadas ligeiramente mais baixa. É ainda de ressaltar que para pessoas menos pesadas, nomeadamente as 5 mais leves, temos apenas um valor acima de 90%.

Sendo assim, começámos por, usando árvores de decisão criadas usando o programa CART® versão 4.0, verificar se seria possível classificar o sujeito quanto às suas características corporais (género, altura e peso) utilizando os dados pré-processados. Para posteriormente entrarem em diferentes redes neuronais.

De modo a mostrar a relevância do uso dos dados antes de serem processados começámos por testar com ambos os dados, pré e pós-processamento, apenas para o género. Como se pode observar na tabela 4.2 o uso de dados pré-processamento dá-nos melhores resultados, acerta aproximadamente 96,2% dos sujeitos enquanto que o uso de dados já processados apenas dá uma taxa de 79,7%, ou seja temos uma diferença de 16,5 pontos percentuais.

Procedemos então à criação de árvores de decisão para os parâmetros restantes, altura e peso, sendo que a performance da melhor árvore, escolhida pelo *software*, pode ser observada na tabela 4.3. Para separarmos os dados calculámos a mediana para cada um das variáveis, e foi esse o valor utilizado, de modo a mantermos o mesmo número de




Figura 4.1: Performance do classificador 3-30 treinado e testado com os sujeitos selecionados (Tabela 4.1).

Nós	Amostra de Aprendizagem		Amostra de Teste	
	Masculino	Feminino	Masculino	Feminino
15	92,8	96,5	93,6	93,6
18	95,5	97,9	93,9	93,6
20	97,6	97,9	94,4	95,2
21	98,4	97,9	94,1	94,9
25	98,7	99,7	95,5	95,5
29	99,5	100,0	95,5	96,5

(a) Dados pré-processados

Nós	Amostra de Aprendizagem		Amostra de Teste	
	Masculino	Feminino	Masculino	Feminino
28	84,5	83,7	68,8	70,7
38	84,8	88,8	71,2	70,1
48	90,7	88,0	71,2	69,9
53	90,7	90,4	70,7	69,9
55	89,3	92,5	71,7	69,1
68	93,1	92,3	70,1	69,6

(b) Dados pós-processados

Tabela 4.2: Performance das árvores de decisão - Dados pré-processados vs. pós-processados

sujeitos em ambos os lados. Verificamos que estes classificadores acertam quase 100% dos casos.

De seguida, atendendo a que o uso de árvores de decisão para fazer uma pré seleção é possível. Criaram-se redes neurais separadas por género, altura e peso, os resultados foram os observáveis na tabela 4.4 e as suas matrizes de confusão estão no anexo C.

Podemos observar na tabela 4.5 a performance dos classificadores já otimizados, escolhendo as melhores árvores e redes para cada parâmetro. Esta ronda os 87%, ou seja

Nós	Amostra de Aprendizagem		Amostra de Teste	
	Acima	Abaixo	Acima	Abaixo
29	100,0	99,5	98,4	96,3

(a)

Nós	Amostra de Aprendizagem		Amostra de Teste	
	Acima	Abaixo	Acima	Abaixo
28	99,7	100,0	98,9	96,5

(b)

Tabela 4.3: Performance das árvores de decisão. Dados separados pela mediana. (a) Peso; (b) Altura.

Camadas	Neurónios	Género	Performance
2	30	Masc.	87,0
		Fem.	87,6
3	30	Masc.	85,8
		Fem.	92,1

Camadas	Neurónios	Peso	Performance
2	30	Acima	87,7
		Abaixo	90,6
3	30	Acima	87,8
		Abaixo	89,3

Camadas	Neurónios	Altura	Performance
2	30	Acima	89,8
		Abaixo	86,4
3	30	Acima	89,2
		Abaixo	88,6

Tabela 4.4: Performance das redes neuronais para cada um dos fatores analisados: género, peso e altura.

temos um aumento de aproximadamente 2% em relação ao classificador mostrado na figura 4.1.

Concluindo observamos que uma pré-separação tendo por base os dados pré-processados resultam em classificações com maiores percentagens de acertos, não aumentando demasiado a complexidade do sistema. Sendo assim, podemos observar na figura 4.2 o fluxograma de classificação, o classificador (n) é o classificador criado para pessoas com as características do sujeito em questão.

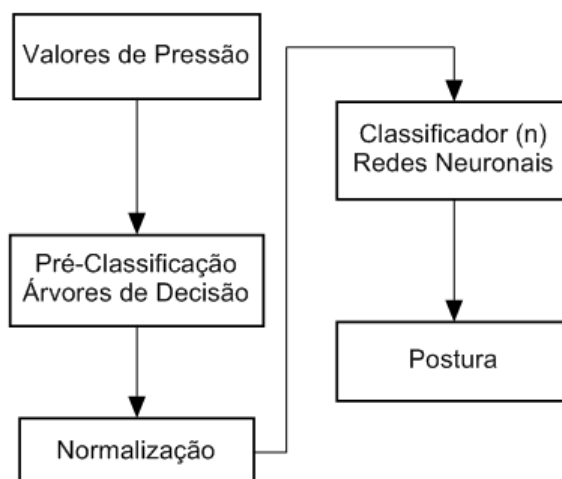


Figura 4.2: Fluxograma da classificação otimizada.

Subgrupo	Árvores de Decisão	Redes Neurais	Total	Geral
Feminino	98,3	92,1	90,5	87,1
Masculino	97,5	85,8	83,7	
Peso abaixo	97,9	89,3	87,4	87,3
Peso acima	98,3	92,1	90,5	
Altura abaixo	98,3	88,6	87,1	87,8
Altura acima	99,3	89,2	88,6	

Tabela 4.5: Sumário da performance resultante da otimização dos classificadores.

4.3 Impacto do Ângulo no Classificador

Usando os dados de 50 aquisições escolhidas aleatoriamente, sendo o único critério haver um igual número de pessoas de ambos os géneros (Tabela 4.6) treinaram-se redes neurais para detetar as posturas P1 a P6 (Fig. 3.5). As restantes foram ignoradas de modo a evitar confusões com as posturas com cruzamento de pernas e inclinação.

Número de Sujeitos (M/F)	Idade(anos)	Peso(Kg)	Altura(cm)
50 (25/25)	26,3±9,9	66,8±12,1	170,9±10,0

Tabela 4.6: Dados dos sujeitos utilizados na construção da rede neuronal

De modo a verificar o comportamento do classificador de redes neurais para diferentes inclinações do sujeito, desenvolveu-se um protocolo de teste.

Pediu-se a cada participante que se inclinasse lentamente para cada um dos lados, parando duas vezes: quando o classificador assumia pela primeira vez que o utilizador estava inclinado para o lado escolhido (Fig. 4.3a), e quando este estabilizava neste ponto (Fig. 4.3b). Sendo tirada, com a sua autorização, uma foto em cada um dos pontos mencionados. É ainda de referir que a câmara foi alinhada com o centro inicial da pessoa de modo a evitar problemas de medição. A experiência foi realizada a 12 participantes (Tabela 4.7). Cada participante repetiu este procedimento 5 vezes para cada lado.

Obtiveram-se assim 240 medidas de ângulos (12 participantes*5 repetições*4 ângulos).

Número de Sujeitos (M/F)	Idade(anos)	Peso(Kg)	Altura(cm)
12 (6/6)	25,8±6,6	72,8±12,1	173,1±10,7

Tabela 4.7: Dados dos participantes na experiência: impacto do ângulo no classificador.

Na figura 4.4 podemos observar o padrão de variação de pressões durante a aquisição. Facilmente se consegue relacionar as oscilações de pressão com os movimentos para a esquerda e para a direita do sujeito. Mais acentuado no assento devido à maior variação de pressões. Vemos ainda, a preto, o resultado da classificação para cada ponto, conseguem-se ver os patamares mencionados anteriormente.




Figura 4.3: Pontos de alteração de comportamento do classificador. (a) Primeira alteração; (b) Estabilização do classificador.

Foi desenvolvida no MATLAB© uma aplicação para efetuar a medição do ângulo em cada um dos momentos mencionados anteriormente (Fig. 4.5). Como se pode observar o utilizador pode ajustar o referencial de modo a estar alinhado com a pessoa. A medição foi feita alinhando o traço horizontal com os ombros da pessoa e o vertical pelo tronco, sendo exibido o ângulo em graus.

A aplicação foi posteriormente usada por três pessoas diferentes para classificar a totalidade das imagens de modo a diminuir a variância induzida pelo avaliador na estatística. Podemos observar os resultados na tabela 4.8.

Analizando os dados da tabela 4.8 verificamos que nos intervalos 11 a 17,6 e 13.5 a 20 graus, para a direita e esquerda, respetivamente, o comportamento do classificador é incerto, isto é, oscila entre dois estados. Foi este comportamento que motivou a inclusão de lógica difusa no classificador, como se pode observar na secção 4.4.

Para fazer uma validação das medições obtidas calcularam-se o coeficiente de correlação intraclasse (ICC) de acordo com as diretrizes de Shrout e Fleiss [44] (modelo: *twoway*, unidade: *average*) recorrendo ao software de análise estatística R versão 3.1.1©.




Figura 4.4: Aquisição de dados. Valores de pressão (linhas coloridas) e postura dada pelo classificador (a preto)

De acordo com Fleiss [45] valores de ICC abaixo de 0,4 significam pobre correlação, de 0.4 a 0.75 boa correlação e a cima deste valor excelente correlação. Podemos então concluir que os valores para o ICC obtidos estão na linha entre o bom e o excelente, à exceção do primeiro ângulo do lado direito, que mesmo assim apresenta uma boa correlação entre medidas.

É ainda feito o teste de Kolmogorov-Smirnov [46] com duas amostras para verificar se os ângulos esquerdo e direito têm a mesma distribuição. A tabela 4.10 mostra os resultados dos testes efetuados para cada sujeito e para cada ângulo com uma significância de 1%. Observamos que no sujeito 7 a hipótese é rejeitada para ambos os ângulos. Vendo a tabela A.2 observamos que este é a pessoa mais leve da amostra. A baixa de performance para participantes mais leves já tinha sido observada na secção 4.2. Uma das possibilidades para este comportamento é a diminuição da pressão efetuada sobre as bolsas.




Figura 4.5: Aplicação para medir o ângulo lateral da inclinação do tronco do sujeito.

	Direita		Esquerda	
Sujeito	1º ângulo	2º ângulo	1º ângulo	2º ângulo
1	10,7±2,2	17,5±2,6	12,9±3,4	20,6±2,4
2	6,5±0,7	11,8±1,1	6,7±1,2	11,4±1,0
3	13,5±2,4	19,6±2,7	16,7±3,6	23,9±2,2
4	8,4±1,4	15,1±1,9	9,2±1,1	14,0±1,6
5	11,6±3,4	22,2±2,9	13,9±3,0	25,7±6,0
6	12,9±2,2	21,4±2,5	17,3±3,5	22,9±5,0
7	16,2±3,6	23,2±2,5	26,7±4,3	35,5±3,3
8	11,3±1,4	17,2±1,6	10,4±1,5	16,8±2,4
9	7,4±1,7	12,9±2,7	10,4±1,6	15,2±1,8
10	11,5±1,4	17,3±2,3	11,5±1,4	17,2±2,1
11	12,0±2,0	16,8±2,4	12,8±1,8	18,1±2,7
12	10,5±2,6	16,6±1,7	13,7±2,3	18,7±2,9
Total	11,0±3,4	17,6±4,0	13,5±5,5	20,0±6,9

Tabela 4.8: Ângulos à qual o comportamento do classificador se alterava.

Medição	ICC
Esquerda - ângulo 1	0,77
Esquerda - ângulo 2	0,70
Direita - ângulo 1	0,53
Direita - ângulo 2	0,74

Tabela 4.9: Coeficiente de correlação intraclasse.

Sujeito	Teste 1	p-value	Teste 2	p-value
1	0	1.6786e-02	0	1.6786e-02
2	0	3.0794e-01	0	8.8990e-01
3	0	5.1467e-02	1	2.3766e-04
4	0	5.8861e-02	0	1.3586e-01
5	0	1.6786e-02	0	5.1467e-02
6	1	4.7152e-03	0	3.0794e-01
7	1	8.7713e-07	1	1.0054e-07
8	0	1.3586e-01	0	5.8861e-01
9	0	5.1467e-02	0	5.1467e-02
10	0	9.9832e-01	0	9.9832e-01
11	0	8.8990e-01	0	3.0794e-01
12	0	5.1467e-02	0	1.6786e-02

Tabela 4.10: Resultados do teste de Kolmogorov-Smirnov.

4.4 Integração de Lógica Fuzzy no Classificador

De modo a aumentar a fiabilidade da classificação postural foi adicionado ao classificador otimizado (Fig. 4.2) um novo bloco que inclui o sistema de classificação fuzzy (Fig. 4.6).

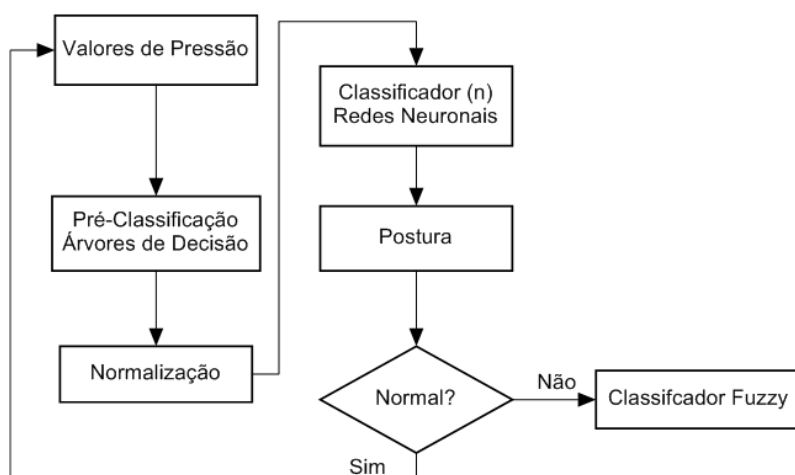


Figura 4.6: Fluxograma de classificação com o bloco fuzzy.

O classificador difuso (Fig. 4.7) foi criado usando a interface gráfica da *toolbox* do MATLAB© *Fuzzy Logic Toolbox*TM.

Este tem como entradas os centros de pressão do assento e das costas, separados nas componentes x e y/z e o tempo numa posição incorreta. Como observamos na figura 4.6 apenas entramos neste bloco caso a postura tenha sido classificada como incorreta (diferente de P1). Ou seja, apenas vamos verificar o grau de inadequabilidade da postura.

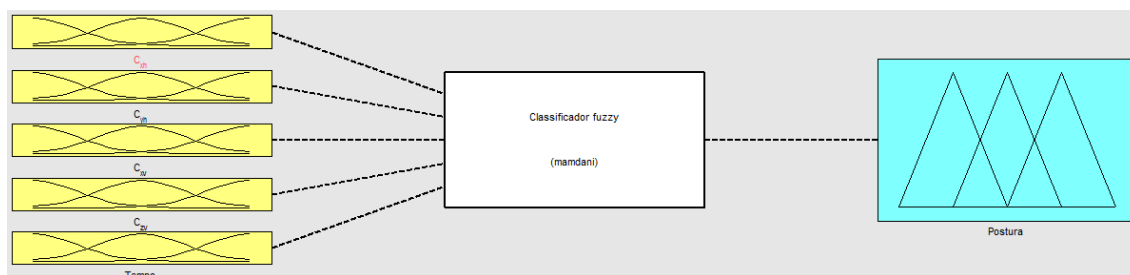


Figura 4.7: Diagrama do bloco fuzzy.

Tendo sido definidas quais as variáveis a utilizar foi preciso escolher as funções de pertinência e atribuir-lhes variáveis linguísticas, de modo a criar, mais tarde, as regras. Nesta fase inicial optámos por usar funções de pertinência triangulares para não aumentar desnecessariamente a complexidade do sistema. É necessário em trabalhos futuros fazer a otimização destes parâmetros.

Para o centro de pressão fizemos uma divisão igual cobrindo todo o espectro possível de valores que este pode tomar ($\pm 8, 5cm$ em x (Fig. 4.8) e $\pm 10, 5cm$ em y/z).

Para o tempo numa posição incorreta fizemos uma divisão semelhante até 15 minutos




Figura 4.8: Função de pertinência para o centro de pressão. Componente x horizontal(assento).

(Fig. 4.9), este tempo foi escolhido seguindo as recomendações *ISO 11226 - Ergonomics — Evaluation of static working postures* [8].




Figura 4.9: Função de pertinência para o tempo numa posição incorreta.

Para a saída do classificador usámos a mesma estratégia, criando 3 zonas, Boa, Aceitável e Má, variando esta no intervalo de 0 a 1 (Fig. 4.10).




Figura 4.10: Função de pertinência para a saída do classificador.

Tendo as funções de pertinência definidos passámos à criação das regras, estas podem ser observadas na tabela 4.11.

Se (Tempo é muito alto) então (Postura é Má)
Se (Tempo é curto) então (Postura é Boa)
Se (C_{xh} é Muito à direita) ou (C_{yh} é Muito á frente) então (Postura é Má)
Se (C_{xv} é Muito à direita) ou (C_{zv} é Muito acima) então (Postura é Má)
Se (C_{xh} é Muito à Esquerda) ou (C_{yh} é Muito á trás) então (Postura é Má)
Se (C_{xv} é Muito à Esquerda) ou (C_{zv} é Muito abaixo) então (Postura é Má)
Se (C_{xh} é Direita) ou (C_{yh} é Frente)) e (Tempo é alto) então (Postura é Má)
Se ((C_{xv} é Direita) ou (C_{zv} é Cima)) e (Tempo é alto) então (Postura é Má)
Se ((C_{xh} é Esquerda) ou (C_{yh} é Trás)) e (Tempo é alto) então (Postura é Má)
Se ((C_{xv} é Esquerda) ou (C_{zv} é Baixo)) e (Tempo é alto) então (Postura é Má)
Se (C_{xh} é Direita) ou (C_{yh} é Frente)) e (Tempo é aceitável) então (Postura é aceitável)
Se ((C_{xv} é Direita) ou (C_{zv} é Cima)) e (Tempo é aceitável) então (Postura é aceitável)
Se ((C_{xh} é Esquerda) ou (C_{yh} é Trás)) e (Tempo é aceitável) então (Postura é aceitável)
Se ((C_{xv} é Esquerda) ou (C_{zv} é Baixo)) e (Tempo é aceitável) então (Postura é aceitável)

Tabela 4.11: Regras do classificador.

5

Correção

Martins et al. [47] implementaram o primeiro algoritmo de correção que pode ser observado na figura 5.1. A correção da postura é conseguida através da alteração da conformação do assento e das costas da cadeira através da alteração da pressão nas bolsas de ar de modo a provocar desconforto ao utilizador e, consequentemente, a adoção de uma postura mais correta. Este algoritmo tem em conta, além da postura adotada pelo sujeito, o fator tempo a dois níveis. Em primeiro lugar o tempo total de utilização da cadeira, permanecer sentado durante longos períodos de tempo mesmo que numa posição correta, pode ser prejudicial. Em segundo lugar o tempo numa posição incorreta, uma vez que se esta for mantida durante um curto período de tempo não tem efeitos nefastos para a saúde do utilizador.

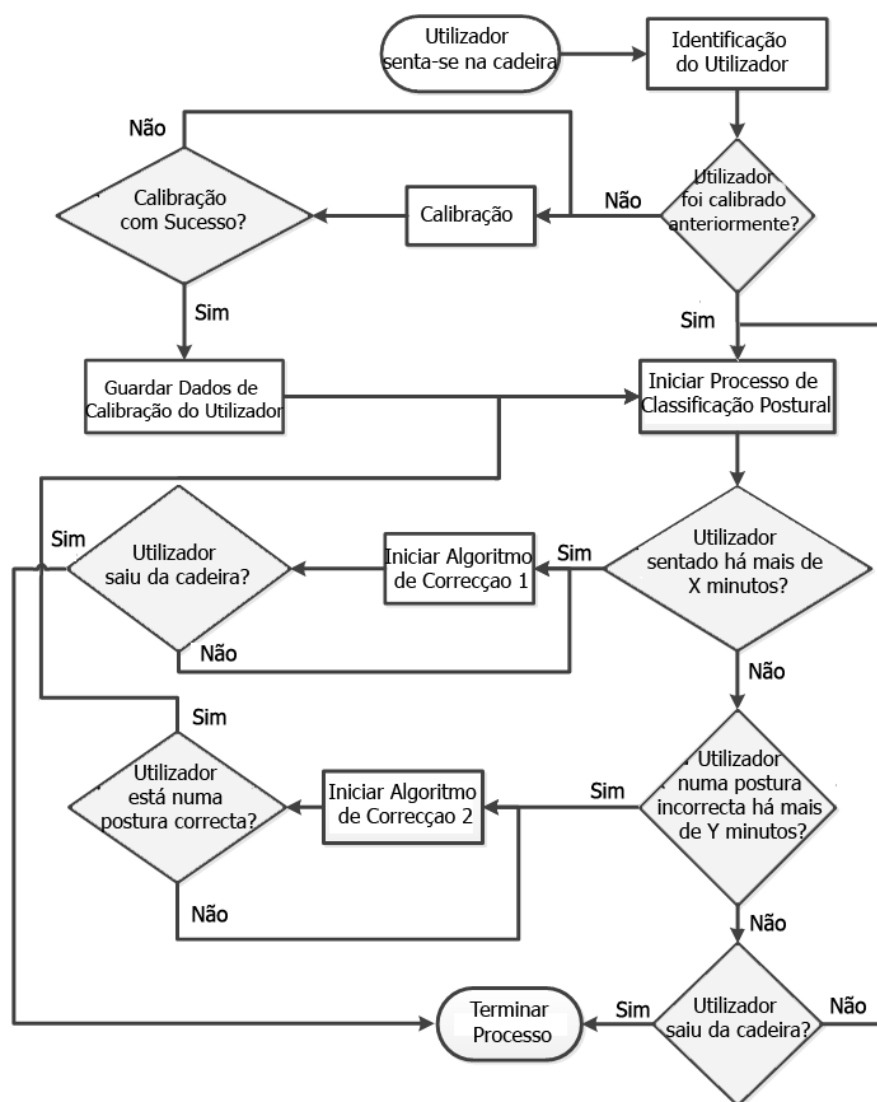


Figura 5.1: Fluxograma do processo de correção de postura [47].

5.1 Pontos de atuação

Procedemos a uma análise dos dados recolhidos para perceber a distribuição das pressões em cada uma das posições, podendo então desenvolver estratégias para a correção da postura.

Nas figuras B.4 e B.5 observamos os diagramas de caixa-de-bigodes para cada uma das posturas criados a partir dos dados das 72 aquisições efetuadas (Tabela 3.1 e Anexo A.1). Usando estes dados em conjunto as distribuições do centro de pressão (Anexo B.2), foram definidos os pontos de atuação para cada uma das posturas (Fig. 5.2). É necessário futuramente fazer uma validação dos pontos de atuação.




Figura 5.2: Pontos de atuação para cada uma das posturas. A tabela de cima representa as costas da cadeira, e a debaixo o assento.

5.2 Sistema de Controlo

Tendo definido os pontos de atuação (Secção 5.1) e o algoritmo de classificação (Secção 4.4), procedemos ao desenvolvimento do fluxograma completo do comportamento do sistema (Fig. 5.3). Foi inserida uma verificação do tempo total de uso do sistema, uma vez que, tal como foi referido anteriormente, permanecer sentado durante longos período de tempo mesmo que numa posição correta, pode ser prejudicial. O valor de tempo X dever estar entre 90 e 180 minutos [47].

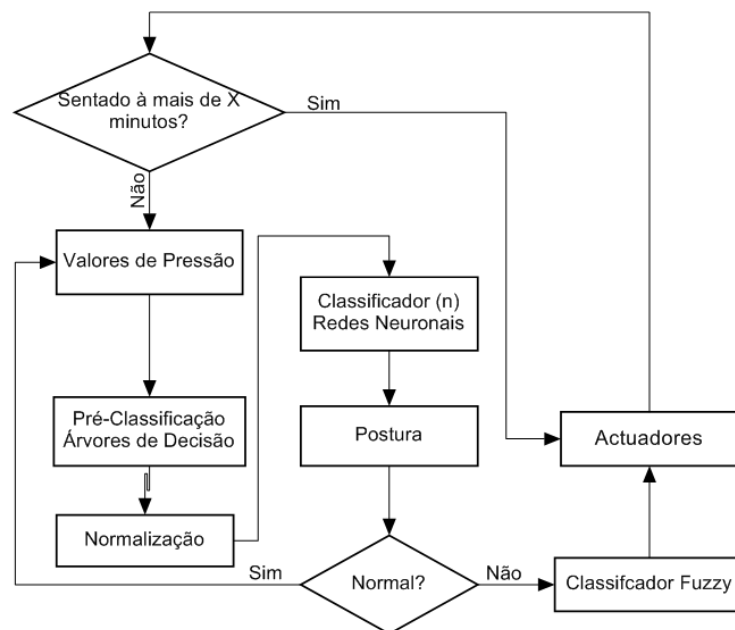


Figura 5.3: Fluxograma do funcionamento do sistema de correção.

O tempo de atuação é definido de acordo com a saída do classificador fuzzy, fazendo uma conversão do intervalo $[0; 1]$, para o intervalo $[0; 10]$ segundos. Este tempo foi definido experimentalmente, sendo que foi escolhido uma vez que era um valor que

induzia já uma quantidade considerável de desconforto.

Por exemplo se o resultado for 0,89 (Postura Má), o sistema irá atuar durante 8,9 segundos. Ou seja as bolsas definidas para a atuar para a posição em questão (Secção 5.1) irão ser enchidas durante os 8.9 segundos, sendo posteriormente esvaziadas. Caso a pessoa não corrija a postura, na próxima atuação, os atuadores irão atuar durante mais tempo uma vez que passou mais tempo, logo a classificação será pior.

Conclusões e trabalho futuro

Nesta dissertação fez-se um estudo sobre a possibilidade de otimizar o classificador de acordo com o peso, altura e/ou género do sujeito. A importância desta otimização está no facto de, sendo o objetivo final deste projeto o funcionamento independente do sistema SYPEC, este terá de ser o mais adaptável possível, mantendo uma elevada taxa de acertos na classificação mesmo sem haver lugar à identificação da pessoa. O resultado obtido foi aproximadamente 87% para todos os parâmetros, ou seja um aumento de 2% relativamente à classificação sem otimizações antropométricas. Está planeado o envio deste trabalho para um artigo no *IEEE Sensors Journal*.

Analizou-se a influência do ângulo lateral do tronco do sujeito nas saídas do classificador. Foi verificada a existência de três zonas: zona onde a postura P1 é identificada, zona intermitente e zona onde a postura lateral é identificada. A zona intermitente foi identificada como estando nos intervalos 11 a 17,6 e 13,5 a 20 graus em relação ao plano mediano, para a direita e esquerda, respetivamente.

Devido ao comportamento intermitente da classificação pelas redes neuronais e a sua incapacidade de identificar posturas intermédias procuraram-se outras alternativas. Isso motivou a inclusão de lógica fuzzy no classificador postural. Este tem em conta os centros de pressão no assento e nas costas da cadeira e o tempo numa postura incorrecta (seguindo as recomendações da norma *ISO 11226 - Ergonomics — Evaluation of static working postures* [8]). O processo de classificação recorrendo à lógica fuzzy foi submetido para a HEALTHINF 2015, 8th *International Conference on Health Informatics*, parte da BIOSTEC, 8th *International Joint Conference on Biomedical Engineering Systems and Technologies*, que vai ser realizada em Lisboa..

Desenvolveu-se um algoritmo de correção que recebe a saída do classificador e produz alterações à conformação da cadeira numa zona específica determinada pela postura

adotada de modo a levar o utilizador a adotar uma postura menos prejudicial. Está planejado o envio deste trabalho para a revista *IEEE Transactions on Fuzzy Systems*.

Não foi possível testar o sistema de correção de postura em ambiente laboral/clínico devido ao seu ruído (capítulo 3.1). É então necessário efetuar estes testes, num trabalho futuro, aquando da existência de novos protótipos com essa falha colmatada. Sendo usado esse trabalho para fazer uma otimização dos parâmetros, nomeadamente as funções de pertença do classificador fuzzy, pontos e tempo de atuação.

Como trabalho futuro é ainda necessário fazer um estudo sobre a influência do ângulo na flexão e extensão do tronco e flexão lateral nas posições com cruzar de pernas. Por restrições de ordem temporal este objetivo inicial não foi cumprido estando, no entanto, prevista a continuação deste trabalho. Tendo sido submetida uma candidatura para o Programa de Estímulo à Investigação da Fundação Calouste Gulbenkian nesse sentido.

Bibliografia

- [1] J. Hartvigsen, C. Leboeuf-Yde, S. Lings e E. H. Corder. "Review Article: Is sitting-while-at-work associated with low back pain? A systematic, critical literature review". Em: *Scandinavian Journal of Public Health* 28.3 (2000), pp. 230–239.
- [2] Y. Zheng e J. B. Morrell. "A vibrotactile feedback approach to posture guidance". Em: *Haptics Symposium, 2010 IEEE*. IEEE. 2010, pp. 351–358.
- [3] M. Adams e W. Hutton. "The effect of posture on the lumbar spine". Em: *Journal of Bone & Joint Surgery, British Volume* 67.4 (1985), pp. 625–629.
- [4] M. Santos. "SYPEC: Desenvolvimento de Classificadores para Identificação Automática da Postura de Sentado". Em: *Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa*. Dissertação de Mestrado em Engenharia Biomédica, 2013.
- [5] E.N. Corlett. "Background to sitting at work: research-based requirements for the design of work seats". Em: *Ergonomics* 49.14 (2006), pp. 1538–1546.
- [6] A. P. Claus, J. A. Hides, G. L. Moseley e P. W. Hodges. "Is 'ideal' sitting posture real?: Measurement of spinal curves in four sitting postures". Em: *Manual Therapy* 14.4 (2009), pp. 404–408.
- [7] J. Pynt, J. Higgs e M. Mackey. "Seeking the optimal posture of the seated lumbar spine". Em: *Physiotherapy theory and practice* 17.1 (2001), pp. 5–21.
- [8] ISO 11226 - *Ergonomics — Evaluation of static working postures*. Norm. 2000.
- [9] M. Adams e W. Hutton. "The effect of posture on the fluid content of lumbar intervertebral discs". Em: *Spine* 8.6 (1983), pp. 665–671.
- [10] E. Grandjean. *Ergonomics in computerized offices*. CRC Press, 2002.
- [11] A. Maroudas, R. Stockwell, A. Nachemson e J. Urban. "Factors involved in the nutrition of the human lumbar intervertebral disc: cellularity and diffusion of glucose in vitro." Em: *Journal of anatomy* 120.Pt 1 (1975), p. 113.
- [12] R. Lueder. *Anatomical, physiological and health*. Humanics ErgoSystems, Inc., 2002.

- [13] H. Z. Tan, L. A. Slivovsky e A. Pentland. "A sensing chair using pressure distribution sensors". Em: *Mechatronics, IEEE/ASME Transactions on* 6.3 (2001), pp. 261–268.
- [14] L. A. Slivovsky e H. Z. Tan. "A real-time sitting posture tracking system". Em: (2000).
- [15] S. Mota e R. W. Picard. "Automated posture analysis for detecting learner's interest level". Em: *Computer Vision and Pattern Recognition Workshop, 2003. CVPRW'03. Conference on*. Vol. 5. IEEE. 2003, pp. 49–49.
- [16] M. Zhu, A. M. Martinez e H. Z. Tan. "Template-based recognition of static sitting postures". Em: *Computer Vision and Pattern Recognition Workshop, 2003. CVPRW'03. Conference on*. Vol. 5. IEEE. 2003, pp. 50–50.
- [17] G. Andreoni, G. C. Santambrogio, M. Rabuffetti e A. Pedotti. "Method for the analysis of posture and interface pressure of car drivers". Em: *Applied Ergonomics* 33.6 (2002), pp. 511–522.
- [18] B. Mutlu, A. Krause, J. Forlizzi, C. Guestrin e J. Hodgins. "Robust, low-cost, non-intrusive sensing and recognition of seated postures". Em: *Proceedings of the 20th annual ACM symposium on User interface software and technology*. ACM. 2007, pp. 149–158.
- [19] I. Daian, A. Van Ruiten, A. Visser e S. Zubic. "Sensitive chair: a force sensing chair with multimodal real-time feedback via agent". Em: *Proceedings of the 14th European conference on Cognitive ergonomics: invent! explore!* ACM. 2007, pp. 163–166.
- [20] Wellnomics. *WorkPace*. Acedido em: Março 2014. URL: <http://workspace.com/workspace/about/what-is-workpace/>.
- [21] EagerPlanet. *RSI-Shield*. Acedido em: Março 2014. URL: <http://www.eagerplanet.com/rsishield>.
- [22] J. da Fonseca. "Indução de Árvores de decisão". Tese de doutoramento. Dissertação de Mestrado, Universidade Nova de Lisboa, Lisboa, 1994.
- [23] A. Miller, B. Blott et al. "Review of neural network applications in medical imaging and signal processing". Em: *Medical and Biological Engineering and Computing* 30.5 (1992), pp. 449–464.
- [24] W. G. Baxt. "Application of artificial neural networks to clinical medicine". Em: *The lancet* 346.8983 (1995), pp. 1135–1138.
- [25] A. Hart e J. Wyatt. "Connectionist models in medicine: An investigation of their potential". Em: *AIME* 89. Springer, 1989, pp. 115–124.
- [26] D. T. Larose. "Discovering Knowledge in Data: An Introduction to Data Mining". Em: (2004).
- [27] L. Breiman, J. Friedman, C. J. Stone e R. A. Olshen. *CART: Classification and regression trees*. CRC press, 1984.

- [28] R. Timofeev. "Classification and regression trees (cart) theory and applications". Tese de doutoramento. Humboldt University, Berlin, 2004.
- [29] L. A. Zadeh. "Fuzzy sets". Em: *Information and control* 8.3 (1965), pp. 338–353.
- [30] C.-T. Lin e C. S. G. Lee. "Neural-network-based fuzzy logic control and decision system". Em: *Computers, IEEE Transactions on* 40.12 (1991), pp. 1320–1336.
- [31] J.-S. Jang e C.-T. Sun. "Neuro-fuzzy modeling and control". Em: *Proceedings of the IEEE* 83.3 (1995), pp. 378–406.
- [32] S. Suryanarayanan, N. P. Reddy e E. P. Canilang. "A fuzzy logic diagnosis system for classification of pharyngeal dysphagia". Em: *International journal of bio-medical computing* 38.3 (1995), pp. 207–215.
- [33] R. Ranjan, A. Awasthi, N. Aggarawal e J. Gulati. "Applications of fuzzy and neuro-fuzzy in biomedical health sciences". Em: *Electro/information Technology, 2006 IEEE International Conference on*. IEEE. 2006, pp. 60–65.
- [34] A. Balbinot e G. Favieiro. "A neuro-fuzzy system for characterization of arm movements". Em: *Sensors* 13.2 (2013), pp. 2613–2630.
- [35] A. Torres e J. J. Nieto. "Fuzzy logic in medicine and bioinformatics". Em: *BioMed Research International* 2006 (2006).
- [36] C.-F. Juang e C.-M. Chang. "Human body posture classification by a neural fuzzy network and home care system application". Em: *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on* 37.6 (2007), pp. 984–994.
- [37] A. Gopalai, S. Senanayake e K. Lim. "Dept. of Electr. & Comput. Eng., Curtin Univ., Miri, Malaysia". Em: *Intelligent Systems Design and Applications (ISDA), 2012 12th International Conference on*. IEEE. 2012, pp. 973–978.
- [38] C. R. Leite, G. Sizilio, A. Neto, R. Valentim e A. Guerreiro. "A fuzzy model for processing and monitoring vital signs in ICU patients". Em: *BioMedical Engineering Online (Online)* 10 (2011), p. 68.
- [39] R. Lucena. "SYPEC: Construção de um Protótipo". Em: *Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa*. Dissertação de Mestrado em Engenharia Biomédica, 2012.
- [40] L. Martins. "Relatório de Bolsa de Investigação no âmbito do projecto QREN 13330 – SYPEC". Em: (2013).
- [41] H. Pereira. "Relatório de Bolsa de Investigação no âmbito do projecto QREN 13330 – SYPEC". Em: (2014).
- [42] J. Belo. "SYPEC: Desenvolvimento de uma aplicação Android para controlo e avaliação postural". Em: *Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa*. Dissertação de Mestrado em Engenharia Biomédica, 2012.

- [43] L. Martins, R. Lucena, J. Belo, M. Santos, C. Quaresma, A. P. Jesus e P. Vieira. "Intelligent Chair Sensor - Classification of Sitting Posture". Em: *Engineering Applications of Neural Networks*. Springer, 2013, pp. 182–191.
- [44] P. E. Shrout e J. L. Fleiss. "Intraclass correlations: uses in assessing rater reliability." Em: *Psychological bulletin* 86.2 (1979), p. 420.
- [45] J. L. Fleiss. "Reliability of measurement". Em: *The design and analysis of clinical experiments* (1986), pp. 1–32.
- [46] F. J. Massey Jr. "The Kolmogorov-Smirnov test for goodness of fit". Em: *Journal of the American statistical Association* 46.253 (1951), pp. 68–78.
- [47] L. Martins, R. Lucena, R. Almeida, J. Belo, C. Quaresma, A. Jesus e P. Vieira. "Intelligent Chair Sensor: Classification and Correction of Sitting Posture". Em: *International Journal of System Dynamics Applications (IJSDA)*. 2014, pp. 65–80.



Anexo I - Participantes nas Experiências

A.1 Participantes na recolha de dados para calibração do sistema SYPEC

Sujeito	Idade(anos)	Sexo	Peso(Kg)	Altura(cm)	Profissão
1	23	M	63	173	Estudante
2	27	M	82	175	Engenheiro Biomédico
3	27	M	97	172	Investigador
4	25	F	54	157	Estudante
5	25	M	96	171	Aluno Doutorado
6	24	F	52	160	Investigador
7	46	M	85	170	Professor
8	29	F	59	163	Fotógrafa
9	25	M	69	181	Estudante
10	23	F	62	161	Estudante
11	27	M	66	170	Estudante
12	25	M	92	197	Investigador
13	26	M	83	184	Consultor
14	23	M	60	165	Estudante
15	20	F	58	165	Estudante

Sujeito	Idade(anos)	Sexo	Peso(Kg)	Altura(cm)	Profissão
16	23	M	90	190	Estudante
17	22	M	72	182	Estudante
18	22	M	68	184	Estudante
19	23	F	55	172	Investigador
20	21	F	69	176	Estudante
21	25	F	50	157	Estudante
22	21	M	68	175	Estudante
23	21	M	85	178	Estudante
24	25	M	75	180	Estudante
25	22	M	72	180	Estudante
26	20	F	55	163	Estudante
27	20	F	60	164	Estudante
28	21	F	73	170	Estudante
29	23	M	77	178	Estudante
30	21	F	54	169	Estudante
31	24	M	63	178	Estudante
32	25	M	63	170	Estudante
33	21	F	53	166	Estudante
34	33	M	75	182	Investigador(Post doc)
35	33	F	56	163	Investigador(Post doc)
36	53	M	87	180	Professor
37	50	F	70	159	Secretária
38	23	M	70	187	Estudante
39	22	F	50	167	Estudante
40	20	F	67	172	Estudante
41	46	F	67	163	Investigador (Post Doc)
42	18	F	47	153	Estudante
43	23	M	64	177	Estudante
44	24	M	80	179	Estudante
45	23	M	65	165	Estudante
46	60	F	61	156	Professora
47	51	F	56	168	Professora
48	51	F	63	156	Professora
49	23	F	44	160	Estudante
50	23	F	58	156	Estudante
51	21	M	63	177	Estudante
52	23	F	53	163	Estudante
53	22	F	80	170	Estudante
54	41	F	105	162	Técnica administrativa
55	42	F	64	161	Professora
56	37	M	59	170	Investigador
57	17	M	76	171	Estudante
58	21	F	65	158	Estudante
59	27	F	48	162	Arquiteta
60	25	F	63	164	Estudante

Sujeito	Idade(anos)	Sexo	Peso(Kg)	Altura(cm)	Profissão
61	22	M	65	175	Estudante
62	21	F	68	168	Estudante
63	21	F	64	173	Estudante
64	21	M	74	184	Estudante
65	21	M	78	185	Estudante
66	18	F	56	160	Estudante
67	18	M	72	174	Estudante
68	23	F	58	172	Estudante
69	27	M	76	176	Consultor
70	25	M	75	178	Estudante
71	26	M	65	172	Bolseiro
72	22	M	84	187	Estudante

A.2 Participantes na experiência da avaliação da influência do ângulo no classificador

Sujeito	Idade(anos)	Sexo	Peso(Kg)	Altura(cm)	Profissão
1	26	M	96	171	Investigador
2	27	M	100	172	Investigador
3	22	F	69	176	Estudante
4	22	F	68	169	Estudante
5	25	F	52	162	Investigador
6	46	M	85	170	Professor
7	21	F	47	158	Estudante
8	24	F	57	171	Estudante
9	24	M	85	190	Estudante
10	26	M	64	172	Investigador
11	25	M	92	197	Investigador
12	22	F	59	169	Estudante



Anexo II - Análises dos Dados Adquiridos

B.1 Diagramas caixa-de-bigodes

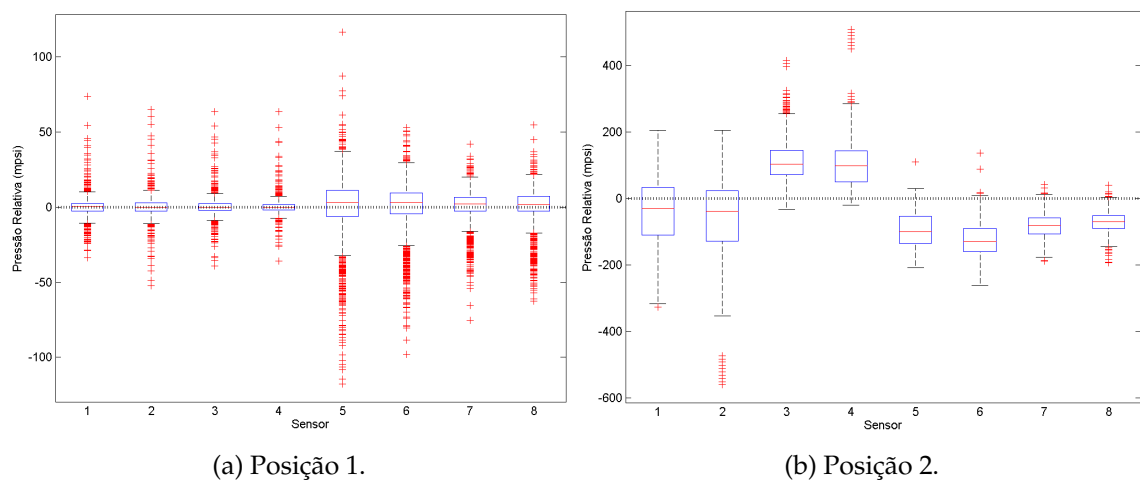





Figura B.1: Diagrama de caixa de bigodes das posições 1 e 2.




(a) Posição 3.




(b) Posição 4.




(c) Posição 5.



(d) Posição 6.



(e) Posição 7.



(f) Posição 8.

Figura B.2: Diagrama de caixa de bigodes das posições 3 a 8.

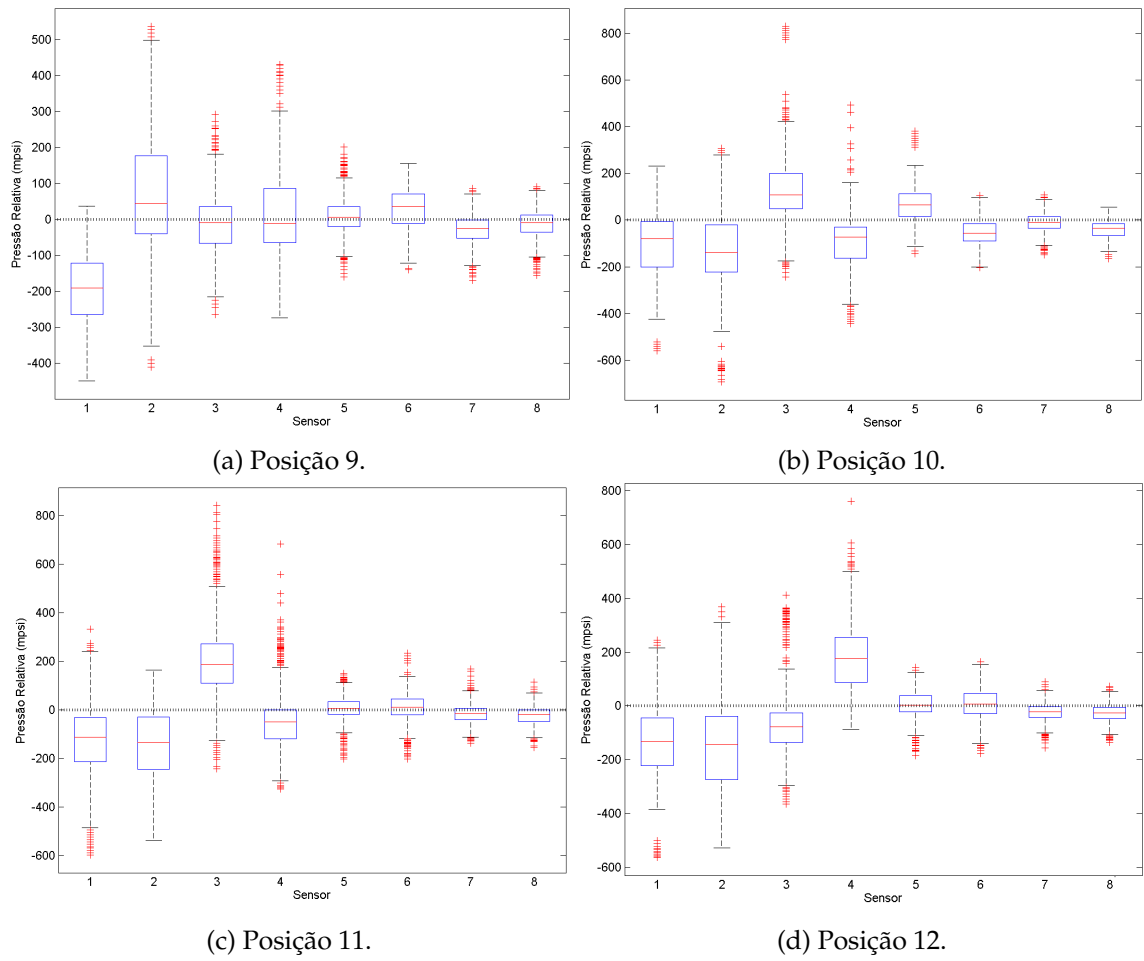


Figura B.3: Diagrama de caixa de bigodes das posições 9 a 12.

B.2 Gráficos - Centro de Pressão

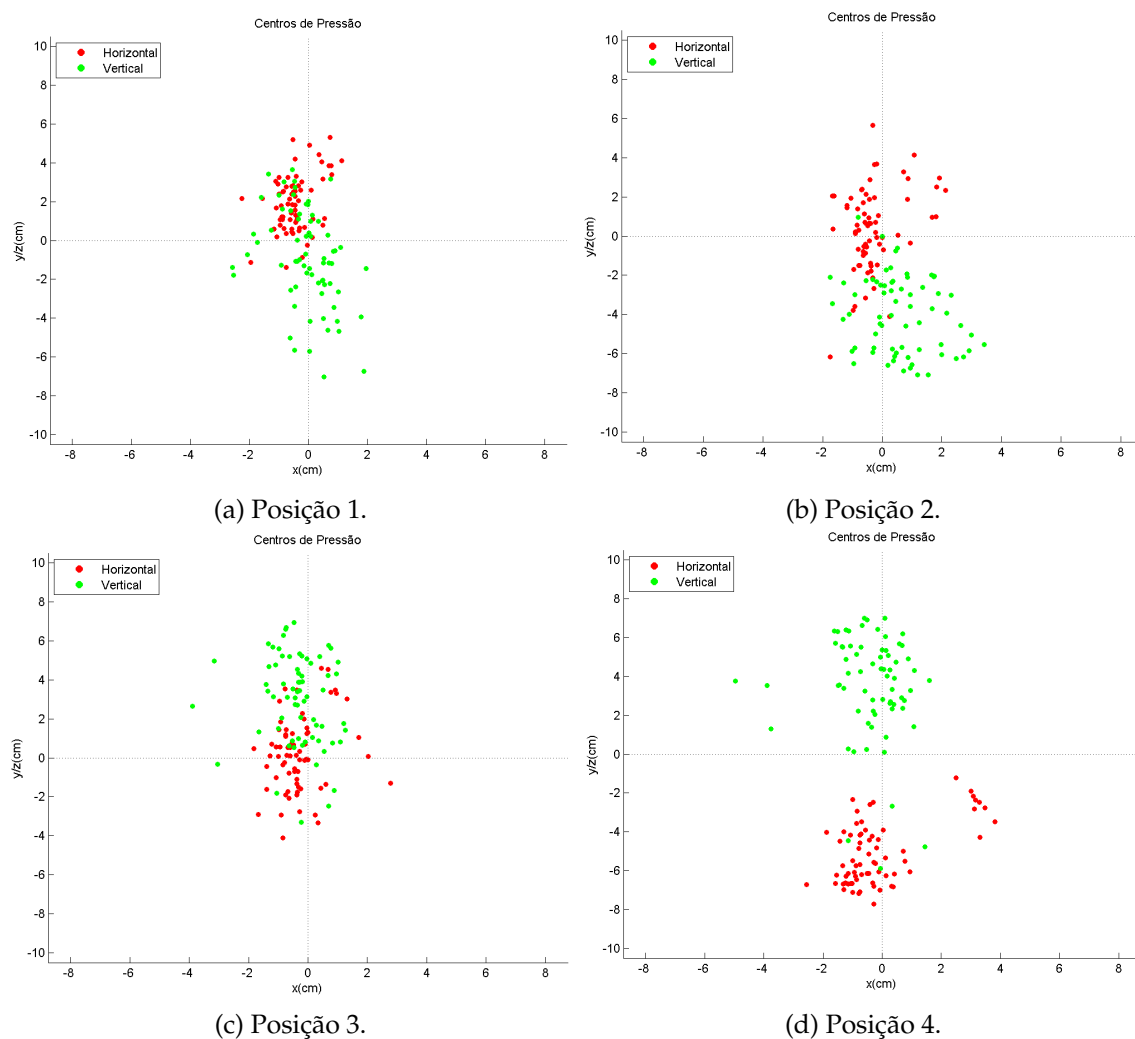


Figura B.4: Centros de pressão das posições 1 a 4.




Figura B.5: Centros de pressão das posições 5 a 8.




Figura B.6: Centros de pressão das posições 9 a 12.



Anexo III - Matrizes de Confusão

Classe alvo	1	697 15.5%	8 0.2%	33 0.7%	2 0.0%	2 0.0%	3 0.1%	93.6% 6.4%
	2	5 0.1%	727 16.2%	6 0.1%	2 0.0%	12 0.3%	3 0.1%	96.3% 3.7%
	3	45 1.0%	11 0.2%	694 15.4%	22 0.5%	0 0.0%	10 0.2%	88.7% 11.3%
	4	0 0.0%	2 0.0%	12 0.3%	724 16.1%	4 0.1%	1 0.0%	97.4% 2.6%
	5	0 0.0%	1 0.0%	4 0.1%	0 0.0%	724 16.1%	1 0.0%	99.2% 0.8%
	6	3 0.1%	1 0.0%	1 0.0%	0 0.0%	8 0.2%	732 16.3%	98.3% 1.7%
		92.9% 7.1%	96.9% 3.1%	92.5% 7.5%	96.5% 3.5%	96.5% 3.5%	97.6% 2.4%	95.5% 4.5%
		1	2	3	4	5	6	
		Classe Obtida						

Figura C.1: Matriz de confusão - 1 camadas - 40 neurónios - P1 a P6.

Classe alvo	1	679 7.5%	8 0.1%	28 0.3%	6 0.1%	1 0.0%	2 0.0%	1 0.0%	1 0.0%	10 0.1%	4 0.0%	0 0.0%	0 0.0%	91.8% 8.2%
	2	5 0.1%	720 8.0%	8 0.1%	3 0.0%	8 0.1%	7 0.1%	16 0.2%	5 0.1%	3 0.0%	10 0.1%	3 0.0%	1 0.0%	91.3% 8.7%
	3	19 0.2%	4 0.0%	634 7.0%	21 0.2%	1 0.0%	8 0.1%	39 0.4%	3 0.0%	28 0.3%	8 0.1%	3 0.0%	5 0.1%	92.0% 18.0%
	4	0 0.0%	0 0.0%	10 0.1%	697 7.7%	5 0.1%	1 0.0%	0 0.0%	2 0.0%	6 0.1%	0 0.0%	4 0.2%	15 0.2%	94.2% 5.8%
	5	0 0.0%	5 0.1%	0 0.0%	0 0.0%	687 7.6%	1 0.0%	30 0.3%	4 0.0%	2 0.0%	47 0.5%	28 0.3%	0 0.0%	95.4% 14.6%
	6	0 0.0%	2 0.0%	0 0.0%	2 0.0%	6 0.1%	600 6.7%	0 0.0%	63 0.7%	15 0.2%	1 0.0%	1 0.0%	25 0.3%	93.9% 16.1%
	7	13 0.1%	1 0.0%	36 0.4%	15 0.2%	11 0.1%	13 0.1%	540 6.0%	25 0.3%	34 0.4%	11 0.1%	17 0.2%	10 0.1%	94.4% 25.6%
	8	0 0.0%	1 0.0%	4 0.0%	2 0.0%	0 0.0%	80 0.9%	22 0.2%	594 6.6%	13 0.1%	5 0.1%	1 0.0%	20 0.2%	90.1% 19.9%
	9	34 0.4%	1 0.0%	11 0.1%	1 0.0%	2 0.0%	23 0.3%	16 0.2%	10 0.1%	582 6.5%	51 0.6%	6 0.1%	12 0.1%	97.7% 22.3%
	10	0 0.0%	5 0.1%	13 0.1%	1 0.0%	23 0.3%	1 0.0%	2 0.0%	1 0.0%	14 0.2%	581 6.5%	14 0.2%	5 0.1%	98.0% 12.0%
	11	0 0.0%	3 0.0%	5 0.1%	2 0.0%	5 0.1%	0 0.0%	47 0.5%	14 0.2%	12 0.1%	18 0.2%	664 7.4%	5 0.1%	95.7% 14.3%
	12	0 0.0%	0 0.0%	1 0.0%	0 0.0%	1 0.0%	14 0.2%	37 0.4%	28 0.3%	31 0.3%	14 0.2%	9 0.1%	652 7.2%	92.8% 17.2%
		90.5%	96.0%	94.5%	92.9%	91.6%	90.0%	92.0%	99.2%	97.6%	97.5%	98.5%	96.9%	94.8%
		9.5%	4.0%	15.5%	7.1%	8.4%	20.0%	28.0%	20.8%	22.4%	22.5%	11.5%	13.1%	15.2%
		1	2	3	4	5	6	7	8	9	10	11	12	
		Classe Obtida												

Figura C.2: Matriz de confusão - 3 camadas - 30 neurónios.

Classe alvo	1	338 7.5%	7 0.2%	9 0.2%	2 0.0%	0 0.0%	2 0.0%	4 0.1%	2 0.0%	2 0.0%	0 0.0%	1 0.0%	0 0.0%	92.1% 7.9%
	2	7 0.2%	352 7.8%	4 0.1%	0 0.0%	2 0.0%	0 0.0%	1 0.0%	1 0.0%	1 0.0%	0 0.0%	0 0.0%	1 0.0%	95.4% 4.6%
	3	11 0.2%	0 0.0%	330 7.3%	12 0.3%	1 0.0%	10 0.2%	18 0.4%	1 0.0%	2 0.0%	3 0.1%	3 0.1%	0 0.0%	94.4% 15.6%
	4	0 0.0%	0 0.0%	8 0.2%	351 7.8%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	97.0% 3.0%
	5	0 0.0%	2 0.0%	2 0.0%	0 0.0%	327 7.3%	1 0.0%	9 0.2%	1 0.0%	0 0.0%	11 0.2%	2 0.0%	0 0.0%	92.1% 7.9%
	6	0 0.0%	0 0.0%	0 0.0%	1 0.0%	1 0.0%	336 7.5%	0 0.0%	9 0.2%	0 0.0%	6 0.1%	1 0.0%	16 0.4%	90.8% 9.2%
	7	5 0.1%	1 0.0%	14 0.3%	1 0.0%	7 0.2%	2 0.0%	265 5.9%	20 0.4%	5 0.1%	9 0.2%	6 0.1%	13 0.3%	96.1% 23.9%
	8	1 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 0.2%	5 0.1%	319 7.1%	5 0.1%	5 0.1%	0 0.0%	16 0.4%	98.6% 11.4%
	9	13 0.3%	6 0.1%	8 0.2%	7 0.2%	2 0.0%	10 0.2%	19 0.4%	9 0.2%	335 7.4%	15 0.3%	14 0.3%	7 0.2%	95.3% 24.7%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.4%	0 0.0%	5 0.1%	0 0.0%	11 0.2%	320 7.1%	11 0.2%	5 0.1%	96.7% 13.3%
	11	0 0.0%	5 0.1%	0 0.0%	0 0.0%	15 0.3%	0 0.0%	35 0.8%	0 0.0%	0 0.0%	1 0.0%	330 7.3%	5 0.1%	94.4% 15.6%
	12	0 0.0%	2 0.0%	0 0.0%	1 0.0%	1 0.0%	5 0.1%	14 0.3%	13 0.3%	14 0.3%	5 0.1%	7 0.2%	311 6.9%	93.4% 16.6%
		90.1%	93.9%	98.0%	93.6%	97.2%	99.6%	90.7%	95.1%	99.3%	95.3%	98.0%	92.9%	97.0%
		9.9%	6.1%	12.0%	6.4%	12.8%	10.4%	29.3%	14.9%	10.7%	14.7%	12.0%	17.1%	13.0%
		1	2	3	4	5	6	7	8	9	10	11	12	
		Classe Obtida												

Figura C.3: Matriz de confusão - 2 camadas - 30 neurónios - Masculino.

1	323 7.2%	4 0.1%	20 0.4%	2 0.0%	1 0.0%	1 0.0%	0 0.0%	2 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	91.0% 9.0%
2	12 0.3%	357 7.9%	4 0.1%	1 0.0%	2 0.0%	0 0.0%	3 0.1%	3 0.1%	0 0.0%	0 0.0%	4 0.1%	1 0.0%	92.2% 7.8%
3	9 0.2%	0 0.0%	308 6.8%	10 0.2%	0 0.0%	0 0.0%	14 0.3%	0 0.0%	4 0.1%	1 0.0%	0 0.0%	0 0.0%	89.0% 11.0%
4	0 0.0%	0 0.0%	5 0.1%	355 7.9%	2 0.0%	5 0.1%	0 0.0%	2 0.0%	5 0.1%	1 0.0%	1 0.0%	5 0.1%	93.2% 6.8%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	333 7.4%	1 0.0%	10 0.2%	0 0.0%	0 0.0%	45 1.0%	0 0.0%	0 0.0%	85.6% 14.4%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	319 7.1%	0 0.0%	21 0.5%	7 0.2%	0 0.0%	1 0.0%	13 0.3%	88.1% 11.9%
7	6 0.1%	0 0.0%	12 0.3%	1 0.0%	5 0.1%	8 0.2%	296 6.6%	5 0.1%	18 0.4%	0 0.0%	5 0.1%	14 0.3%	80.0% 20.0%
8	0 0.0%	0 0.0%	3 0.1%	0 0.0%	0 0.0%	10 0.2%	6 0.1%	332 7.4%	3 0.1%	5 0.1%	2 0.0%	6 0.1%	90.5% 9.5%
9	25 0.6%	0 0.0%	8 0.2%	2 0.0%	2 0.0%	20 0.4%	10 0.2%	3 0.1%	299 6.6%	26 0.6%	15 0.3%	0 0.0%	72.6% 27.4%
10	0 0.0%	6 0.1%	11 0.2%	0 0.0%	16 0.4%	5 0.1%	6 0.1%	0 0.0%	7 0.2%	288 6.4%	6 0.1%	6 0.1%	82.1% 17.9%
11	0 0.0%	6 0.1%	2 0.0%	2 0.0%	11 0.2%	0 0.0%	22 0.5%	0 0.0%	10 0.2%	4 0.1%	328 7.3%	6 0.1%	83.9% 16.1%
12	0 0.0%	2 0.0%	2 0.0%	2 0.0%	2 0.0%	6 0.1%	8 0.2%	7 0.2%	20 0.4%	5 0.1%	13 0.3%	322 7.2%	82.8% 17.2%
	86.1% 13.9%	85.2% 14.8%	82.1% 17.9%	84.7% 15.3%	88.8% 11.2%	85.1% 14.9%	78.9% 21.1%	88.5% 11.5%	79.7% 20.3%	76.8% 23.2%	87.5% 12.5%	85.9% 14.1%	85.8% 14.2%
	1	2	3	4	5	6	7	8	9	10	11	12	

Figura C.4: Matriz de confusão - 3 camadas - 30 neurónios - Masculino.

1	359 8.0%	1 0.0%	16 0.4%	2 0.0%	0 0.0%	1 0.0%	0 0.0%	1 0.0%	2 0.0%	10 0.2%	0 0.0%	0 0.0%	91.6% 8.4%
2	0 0.0%	362 8.0%	2 0.0%	1 0.0%	5 0.1%	5 0.1%	10 0.2%	7 0.2%	4 0.1%	4 0.1%	2 0.0%	5 0.1%	88.9% 11.1%
3	1 0.0%	6 0.1%	321 7.1%	11 0.2%	0 0.0%	1 0.0%	46 1.0%	3 0.1%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	78.5% 21.5%
4	0 0.0%	1 0.0%	9 0.2%	359 8.0%	2 0.0%	5 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	6 0.1%	93.7% 6.3%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	345 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	32 0.7%	3 0.1%	0 0.0%	90.8% 9.2%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 0.1%	314 7.0%	3 0.1%	16 0.4%	5 0.1%	0 0.0%	0 0.0%	3 0.1%	90.8% 9.2%
7	0 0.0%	0 0.0%	23 0.5%	0 0.0%	1 0.0%	4 0.1%	259 5.8%	8 0.2%	0 0.0%	5 0.1%	0 0.0%	3 0.1%	85.5% 14.5%
8	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	23 0.5%	8 0.2%	322 7.2%	1 0.0%	0 0.0%	0 0.0%	3 0.1%	89.9% 10.1%
9	10 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	21 0.5%	2 0.0%	8 0.2%	341 7.6%	19 0.4%	10 0.2%	0 0.0%	83.0% 17.0%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.4%	0 0.0%	0 0.0%	0 0.0%	3 0.1%	251 5.6%	0 0.0%	0 0.0%	92.6% 7.4%
11	5 0.1%	0 0.0%	3 0.1%	2 0.0%	0 0.0%	0 0.0%	5 0.1%	1 0.0%	4 0.1%	29 0.6%	356 7.9%	0 0.0%	87.9% 12.1%
12	0 0.0%	5 0.1%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	42 0.9%	9 0.2%	6 0.1%	15 0.3%	2 0.0%	355 7.9%	81.6% 18.4%
	95.7% 4.3%	86.5% 13.5%	85.6% 14.4%	85.7% 14.3%	82.0% 18.0%	83.7% 16.3%	69.1% 30.9%	85.9% 14.1%	80.9% 19.1%	66.9% 33.1%	84.9% 15.1%	84.7% 15.3%	87.6% 12.4%
	1	2	3	4	5	6	7	8	9	10	11	12	

Figura C.5: Matriz de confusão - 2 camadas - 30 neurónios - Feminino.

Classe alvo	1	356 7.9%	4 0.1%	13 0.3%	2 0.0%	0 0.0%	2 0.0%	1 0.0%	1 0.0%	2 0.0%	4 0.1%	0 0.0%	0 0.0%	32.5% 7.5%
	2	0 0.0%	355 7.9%	2 0.0%	1 0.0%	5 0.1%	2 0.0%	8 0.2%	3 0.1%	2 0.0%	0 0.0%	1 0.0%	0 0.0%	33.7% 6.3%
	3	2 0.0%	5 0.1%	339 7.5%	4 0.1%	0 0.0%	3 0.1%	17 0.4%	2 0.0%	11 0.2%	5 0.1%	0 0.0%	2 0.0%	36.9% 13.1%
	4	0 0.0%	0 0.0%	0 0.0%	360 8.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 0.1%	38.1% 1.9%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	363 8.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 0.2%	0 0.0%	0 0.0%	38.1% 1.9%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 0.1%	334 7.4%	0 0.0%	6 0.1%	4 0.1%	0 0.0%	0 0.0%	7 0.2%	33.8% 6.2%
	7	7 0.2%	6 0.1%	15 0.3%	0 0.0%	0 0.0%	3 0.1%	321 7.1%	1 0.0%	1 0.0%	1 0.0%	2 0.0%	1 0.0%	39.7% 10.3%
	8	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	27 0.6%	13 0.3%	351 7.8%	6 0.1%	0 0.0%	0 0.0%	18 0.4%	34.4% 15.6%
	9	10 0.2%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	2 0.0%	329 7.3%	2 0.0%	10 0.2%	0 0.0%	32.7% 7.3%
	10	0 0.0%	0 0.0%	5 0.1%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	1 0.0%	6 0.1%	347 7.7%	6 0.1%	0 0.0%	34.6% 5.4%
	11	0 0.0%	1 0.0%	1 0.0%	8 0.2%	0 0.0%	1 0.0%	0 0.0%	3 0.1%	3 0.1%	9 0.2%	354 7.9%	5 0.1%	31.9% 8.1%
	12	0 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	13 0.3%	5 0.1%	11 0.2%	0 0.0%	2 0.0%	337 7.5%	30.6% 9.4%
94.9%34.7%30.4%36.0%36.8%39.1%35.6%33.6%37.7%32.5%34.4%39.9%32.1% 5.1%5.3%9.6%4.0%3.2%10.9%4.4%6.4%12.3%7.5%5.6%10.1%7.9%														
12														
Classe Obtida														

Figura C.6: Matriz de confusão - 3 camadas - 30 neurónios - Feminino.

Classe alvo	1	347 7.7%	3 0.1%	23 0.5%	2 0.0%	1 0.0%	1 0.0%	1 0.0%	3 0.1%	7 0.2%	7 0.2%	0 0.0%	0 0.0%	37.8%
	2	1 0.0%	356 7.9%	5 0.1%	1 0.0%	7 0.2%	3 0.1%	6 0.1%	3 0.1%	2 0.0%	0 0.0%	5 0.1%	1 0.0%	31.3%
	3	7 0.2%	11 0.2%	323 7.2%	20 0.4%	0 0.0%	1 0.0%	48 1.1%	8 0.2%	7 0.2%	10 0.2%	11 0.2%	5 0.1%	71.6%
	4	0 0.0%	1 0.0%	4 0.1%	349 7.8%	4 0.1%	0 0.0%	0 0.0%	0 0.0%	8 0.2%	0 0.0%	5 0.1%	15 0.3%	30.4%
	5	0 0.0%	0 0.0%	0 0.0%	2 0.0%	337 7.5%	0 0.0%	9 0.2%	0 0.0%	0 0.0%	21 0.5%	7 0.2%	0 0.0%	39.6%
	6	0 0.0%	2 0.0%	2 0.0%	0 0.0%	8 0.2%	339 7.5%	0 0.0%	22 0.5%	16 0.4%	9 0.2%	0 0.0%	4 0.1%	34.3%
	7	5 0.1%	0 0.0%	11 0.2%	0 0.0%	2 0.0%	9 0.2%	272 6.0%	8 0.2%	0 0.0%	0 0.0%	5 0.1%	9 0.2%	34.7%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 0.3%	4 0.1%	300 6.7%	1 0.0%	0 0.0%	0 0.0%	1 0.0%	33.8%
	9	14 0.3%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	6 0.1%	5 0.1%	4 0.1%	325 7.2%	9 0.2%	10 0.2%	3 0.1%	36.0%
	10	1 0.0%	0 0.0%	6 0.1%	0 0.0%	13 0.3%	0 0.0%	1 0.0%	1 0.0%	1 0.0%	296 6.6%	14 0.3%	7 0.2%	37.1%
	11	0 0.0%	2 0.0%	1 0.0%	0 0.0%	1 0.0%	1 0.0%	10 0.2%	8 0.2%	2 0.0%	12 0.3%	316 7.0%	0 0.0%	39.5%
	12	0 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	1 0.0%	19 0.4%	18 0.4%	6 0.1%	11 0.2%	2 0.0%	330 7.3%	35.1%
		92.5%	34.9%	36.1%	33.1%	39.9%	30.4%	32.5%	30.0%	36.7%	38.9%	34.3%	38.0%	36.4%
		7.5%	5.1%	13.9%	6.9%	10.1%	9.6%	27.5%	20.0%	13.3%	21.1%	15.7%	12.0%	13.6%
		1	2	3	4	5	6	7	8	9	10	11	12	
		Classe Obtida												

Figura C.7: Matriz de confusão - 2 camadas - 30 neurónios - Altura abaixo.

1	350 7.8%	6 0.1%	16 0.4%	2 0.0%	0 0.0%	2 0.0%	3 0.1%	9 0.2%	4 0.1%	13 0.3%	0 0.0%	0 0.0%	36.4% 13.6%
2	1 0.0%	356 7.9%	4 0.1%	1 0.0%	8 0.2%	2 0.0%	8 0.2%	3 0.1%	6 0.1%	0 0.0%	2 0.0%	1 0.0%	90.8% 9.2%
3	7 0.2%	3 0.1%	343 7.6%	17 0.4%	0 0.0%	7 0.2%	26 0.6%	3 0.1%	10 0.2%	10 0.2%	10 0.2%	0 0.0%	78.7% 21.3%
4	0 0.0%	1 0.0%	2 0.0%	353 7.8%	4 0.1%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	6 0.1%	95.7% 4.3%
5	0 0.0%	1 0.0%	0 0.0%	0 0.0%	321 7.1%	3 0.1%	3 0.1%	6 0.1%	0 0.0%	0 0.0%	5 0.1%	0 0.0%	94.7% 5.3%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 0.1%	332 7.4%	2 0.0%	1 0.0%	14 0.3%	3 0.1%	2 0.0%	2 0.0%	92.0% 8.0%
7	3 0.1%	3 0.1%	5 0.1%	0 0.0%	4 0.1%	4 0.1%	287 6.4%	1 0.0%	5 0.1%	3 0.1%	10 0.2%	5 0.1%	87.0% 13.0%
8	0 0.0%	0 0.0%	0 0.0%	2 0.0%	0 0.0%	17 0.4%	2 0.0%	328 7.3%	2 0.0%	0 0.0%	0 0.0%	2 0.0%	92.9% 7.1%
9	14 0.3%	0 0.0%	0 0.0%	0 0.0%	3 0.1%	6 0.1%	3 0.1%	1 0.0%	322 7.2%	5 0.1%	3 0.1%	4 0.1%	89.2% 10.8%
10	0 0.0%	0 0.0%	5 0.1%	0 0.0%	30 0.7%	2 0.0%	14 0.3%	1 0.0%	2 0.0%	324 7.2%	16 0.4%	5 0.1%	81.2% 18.8%
11	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 0.1%	4 0.1%	0 0.0%	8 0.2%	323 7.2%	0 0.0%	95.0% 5.0%
12	0 0.0%	4 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	22 0.5%	18 0.4%	10 0.2%	9 0.2%	2 0.0%	350 7.8%	84.3% 15.7%
	93.3% 6.7%	94.9% 5.1%	91.5% 8.5%	94.1% 5.9%	95.6% 4.4%	98.5% 1.5%	97.5% 2.5%	97.5% 2.5%	95.9% 4.1%	96.4% 3.6%	96.1% 3.9%	93.3% 6.7%	88.6% 11.4%
	1	2	3	4	5	6	7	8	9	10	11	12	
	Classe Obtida												

Figura C.8: Matriz de confusão - 3 camadas - 30 neurónios -Altura abaixo.

1	355 7.9%	5 0.1%	11 0.2%	3 0.1%	0 0.0%	1 0.0%	2 0.0%	0 0.0%	10 0.2%	0 0.0%	0 0.0%	0 0.0%	91.7% 8.3%
2	0 0.0%	368 8.2%	0 0.0%	1 0.0%	3 0.1%	1 0.0%	3 0.1%	1 0.0%	4 0.1%	0 0.0%	0 0.0%	0 0.0%	96.6% 3.4%
3	2 0.0%	2 0.0%	331 7.4%	4 0.1%	0 0.0%	1 0.0%	10 0.2%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	94.3% 5.7%
4	0 0.0%	0 0.0%	10 0.2%	364 8.1%	1 0.0%	1 0.0%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 0.1%	95.0% 5.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	338 7.5%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	10 0.2%	4 0.1%	0 0.0%	95.8% 4.2%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	309 6.9%	0 0.0%	31 0.7%	5 0.1%	0 0.0%	0 0.0%	13 0.3%	86.3% 13.7%
7	9 0.2%	0 0.0%	19 0.4%	0 0.0%	8 0.2%	19 0.4%	318 7.1%	26 0.6%	19 0.4%	0 0.0%	8 0.2%	0 0.0%	74.6% 25.4%
8	4 0.1%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	24 0.5%	1 0.0%	302 6.7%	1 0.0%	0 0.0%	0 0.0%	6 0.1%	89.1% 10.9%
9	5 0.1%	0 0.0%	3 0.1%	1 0.0%	0 0.0%	10 0.2%	6 0.1%	2 0.0%	307 6.8%	4 0.1%	0 0.0%	3 0.1%	90.0% 10.0%
10	0 0.0%	0 0.0%	0 0.0%	2 0.0%	25 0.6%	3 0.1%	3 0.1%	0 0.0%	6 0.1%	355 7.9%	0 0.0%	6 0.1%	88.8% 11.3%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	25 0.6%	0 0.0%	9 0.2%	5 0.1%	356 7.9%	5 0.1%	89.0% 11.0%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	5 0.1%	5 0.1%	13 0.3%	13 0.3%	1 0.0%	7 0.2%	337 7.5%	88.5% 11.5%
	94.7% 5.3%	98.1% 1.9%	98.3% 1.7%	97.1% 2.9%	90.1% 9.9%	92.4% 7.6%	94.8% 5.2%	90.5% 9.5%	91.9% 8.1%	94.7% 5.3%	94.9% 5.1%	99.9% 0.1%	89.8% 10.2%
	1	2	3	4	5	6	7	8	9	10	11	12	
	Classe Obtida												

Figura C.9: Matriz de confusão - 2 camadas - 30 neurónios - Altura acima.

Classe alvo	1	352 7.8%	5 0.1%	16 0.4%	3 0.1%	0 0.0%	0 0.0%	3 0.1%	0 0.0%	5 0.1%	0 0.0%	1 0.0%	0 0.0%	91.4% 8.6%
	2	2 0.0%	370 8.2%	1 0.0%	1 0.0%	1 0.0%	1 0.0%	1 0.0%	1 0.0%	1 0.0%	0 0.0%	0 0.0%	5 0.1%	96.4% 3.6%
	3	5 0.1%	0 0.0%	336 7.5%	12 0.3%	0 0.0%	2 0.0%	17 0.4%	0 0.0%	5 0.1%	0 0.0%	1 0.0%	1 0.0%	98.7% 11.3%
	4	0 0.0%	0 0.0%	5 0.1%	357 7.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	8 0.2%	96.0% 4.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	350 7.8%	1 0.0%	11 0.2%	0 0.0%	10 0.2%	33 0.7%	7 0.2%	0 0.0%	95.0% 15.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	328 7.3%	0 0.0%	15 0.3%	1 0.0%	0 0.0%	0 0.0%	6 0.1%	93.7% 6.3%
	7	10 0.2%	0 0.0%	14 0.3%	0 0.0%	0 0.0%	11 0.2%	298 6.6%	16 0.4%	18 0.4%	20 0.4%	14 0.3%	6 0.1%	97.2% 26.8%
	8	1 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	14 0.3%	3 0.1%	342 7.6%	6 0.1%	0 0.0%	0 0.0%	1 0.0%	92.9% 7.1%
	9	5 0.1%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	1 0.0%	6 0.1%	0 0.0%	307 6.8%	15 0.3%	3 0.1%	1 0.0%	90.6% 9.4%
	10	0 0.0%	0 0.0%	1 0.0%	0 0.0%	18 0.4%	1 0.0%	0 0.0%	0 0.0%	2 0.0%	291 6.5%	4 0.1%	1 0.0%	91.5% 8.5%
	11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 0.1%	0 0.0%	31 0.7%	0 0.0%	1 0.0%	5 0.1%	335 7.4%	0 0.0%	98.6% 11.4%
	12	0 0.0%	0 0.0%	1 0.0%	1 0.0%	0 0.0%	16 0.4%	5 0.1%	1 0.0%	19 0.4%	11 0.2%	8 0.2%	346 7.7%	94.8% 15.2%
		93.9% 6.1%	98.7% 1.3%	99.6% 0.4%	95.2% 4.8%	93.3% 6.7%	97.5% 2.5%	99.5% 0.5%	91.2% 8.8%	91.9% 8.1%	97.6% 2.4%	99.3% 0.7%	92.3% 7.7%	99.2% 0.8%
		1	2	3	4	5	6	7	8	9	10	11	12	
		Classe Obtida												

Figura C.10: Matriz de confusão - 3 camadas - 30 neurónios - Altura acima.

Classe alvo	1	370 8.2%	5 0.1%	16 0.4%	2 0.0%	1 0.0%	2 0.0%	0 0.0%	1 0.0%	9 0.2%	5 0.1%	0 0.0%	0 0.0%	90.0% 10.0%
	2	0 0.0%	365 8.1%	5 0.1%	1 0.0%	7 0.2%	2 0.0%	6 0.1%	3 0.1%	1 0.0%	10 0.2%	7 0.2%	1 0.0%	99.5% 10.5%
	3	5 0.1%	1 0.0%	343 7.6%	7 0.2%	0 0.0%	0 0.0%	1 0.0%	3 0.1%	9 0.2%	7 0.2%	7 0.2%	0 0.0%	99.6% 10.4%
	4	0 0.0%	1 0.0%	5 0.1%	365 8.1%	4 0.1%	1 0.0%	0 0.0%	0 0.0%	3 0.1%	0 0.0%	4 0.1%	6 0.1%	93.8% 6.2%
	5	0 0.0%	0 0.0%	1 0.0%	0 0.0%	327 7.3%	0 0.0%	6 0.1%	0 0.0%	0 0.0%	17 0.4%	3 0.1%	0 0.0%	92.4% 7.6%
	6	0 0.0%	2 0.0%	2 0.0%	0 0.0%	5 0.1%	322 7.2%	0 0.0%	7 0.2%	7 0.2%	7 0.2%	2 0.0%	3 0.1%	90.2% 9.8%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	3 0.1%	333 7.4%	0 0.0%	0 0.0%	3 0.1%	0 0.0%	0 0.0%	97.9% 2.1%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	24 0.5%	10 0.2%	341 7.6%	11 0.2%	5 0.1%	0 0.0%	2 0.0%	96.8% 13.2%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	18 0.4%	4 0.1%	1 0.0%	327 7.3%	20 0.4%	1 0.0%	0 0.0%	97.7% 12.3%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 0.2%	1 0.0%	5 0.1%	0 0.0%	2 0.0%	287 6.4%	7 0.2%	5 0.1%	90.5% 9.5%
	11	0 0.0%	1 0.0%	0 0.0%	0 0.0%	15 0.3%	0 0.0%	8 0.2%	6 0.1%	1 0.0%	7 0.2%	338 7.5%	0 0.0%	99.9% 10.1%
	12	0 0.0%	0 0.0%	3 0.1%	0 0.0%	3 0.1%	2 0.0%	2 0.0%	13 0.3%	5 0.1%	7 0.2%	6 0.1%	358 8.0%	99.7% 10.3%
		98.7% 1.3%	97.3% 2.7%	91.5% 8.5%	97.3% 2.7%	97.2% 2.8%	95.9% 4.1%	98.8% 1.2%	90.9% 9.1%	97.2% 2.8%	96.5% 3.5%	90.1% 9.9%	95.5% 4.5%	90.6% 9.4%
		1	2	3	4	5	6	7	8	9	10	11	12	
		Classe Obtida												

Figura C.11: Matriz de confusão - 2 camadas - 30 neurónios - Peso abaixo.

1	362 8.0%	3 0.1%	17 0.4%	3 0.1%	0 0.0%	1 0.0%	4 0.1%	4 0.1%	7 0.2%	5 0.1%	0 0.0%	0 0.0%	39.2% 10.8%
2	6 0.1%	342 7.6%	6 0.1%	1 0.0%	3 0.1%	1 0.0%	6 0.1%	3 0.1%	1 0.0%	0 0.0%	2 0.0%	1 0.0%	91.9% 8.1%
3	2 0.0%	7 0.2%	334 7.4%	6 0.1%	1 0.0%	5 0.1%	11 0.2%	3 0.1%	8 0.2%	6 0.1%	3 0.1%	6 0.1%	85.2% 14.8%
4	0 0.0%	6 0.1%	6 0.1%	363 8.1%	7 0.2%	0 0.0%	0 0.0%	2 0.0%	1 0.0%	0 0.0%	3 0.1%	6 0.1%	92.1% 7.9%
5	2 0.0%	6 0.1%	0 0.0%	0 0.0%	331 7.4%	2 0.0%	6 0.1%	0 0.0%	0 0.0%	13 0.3%	6 0.1%	0 0.0%	90.4% 9.6%
6	0 0.0%	1 0.0%	0 0.0%	0 0.0%	6 0.1%	316 7.0%	0 0.0%	4 0.1%	9 0.2%	5 0.1%	1 0.0%	2 0.0%	91.9% 8.1%
7	3 0.1%	3 0.1%	7 0.2%	1 0.0%	5 0.1%	4 0.1%	333 7.4%	13 0.3%	10 0.2%	7 0.2%	0 0.0%	10 0.2%	84.1% 15.9%
8	0 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	35 0.8%	0 0.0%	320 7.1%	2 0.0%	1 0.0%	0 0.0%	0 0.0%	89.1% 10.9%
9	0 0.0%	4 0.1%	3 0.1%	0 0.0%	2 0.0%	6 0.1%	1 0.0%	1 0.0%	321 7.1%	3 0.1%	0 0.0%	0 0.0%	94.1% 5.9%
10	0 0.0%	2 0.0%	2 0.0%	0 0.0%	16 0.4%	4 0.1%	6 0.1%	5 0.1%	16 0.4%	332 7.4%	17 0.4%	26 0.6%	77.9% 22.1%
11	0 0.0%	1 0.0%	0 0.0%	0 0.0%	4 0.1%	0 0.0%	7 0.2%	9 0.2%	0 0.0%	1 0.0%	340 7.6%	0 0.0%	93.9% 6.1%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	11 0.2%	0 0.0%	2 0.0%	3 0.1%	324 7.2%	94.7% 5.3%
	96.5% 3.5%	91.2% 8.8%	89.1% 10.9%	86.8% 13.2%	88.3% 11.7%	84.3% 15.7%	88.8% 11.2%	85.3% 14.7%	85.6% 14.4%	88.5% 11.5%	90.7% 9.3%	86.4% 13.6%	89.3% 10.7%
	1	2	3	4	5	6	7	8	9	10	11	12	

Figura C.12: Matriz de confusão - 3 camadas - 30 neurónios - Peso abaixo.

1	342 7.6%	8 0.2%	12 0.3%	2 0.0%	0 0.0%	1 0.0%	1 0.0%	1 0.0%	9 0.2%	5 0.1%	0 0.0%	0 0.0%	39.8% 10.2%
2	0 0.0%	355 7.9%	5 0.1%	1 0.0%	1 0.0%	1 0.0%	3 0.1%	1 0.0%	2 0.0%	0 0.0%	4 0.1%	0 0.0%	95.2% 4.8%
3	11 0.2%	0 0.0%	333 7.4%	15 0.3%	0 0.0%	1 0.0%	5 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	91.2% 8.8%
4	0 0.0%	0 0.0%	5 0.1%	350 7.8%	0 0.0%	0 0.0%	4 0.1%	2 0.0%	5 0.1%	0 0.0%	1 0.0%	5 0.1%	94.1% 5.9%
5	0 0.0%	5 0.1%	1 0.0%	0 0.0%	366 8.1%	5 0.1%	22 0.5%	0 0.0%	0 0.0%	36 0.8%	7 0.2%	0 0.0%	92.8% 7.2%
6	4 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	342 7.6%	0 0.0%	38 0.8%	12 0.3%	5 0.1%	0 0.0%	2 0.0%	84.9% 15.1%
7	4 0.1%	2 0.0%	10 0.2%	1 0.0%	0 0.0%	9 0.2%	259 5.8%	1 0.0%	5 0.1%	2 0.0%	1 0.0%	0 0.0%	88.1% 11.9%
8	4 0.1%	0 0.0%	5 0.1%	0 0.0%	0 0.0%	6 0.1%	10 0.2%	306 6.8%	2 0.0%	0 0.0%	0 0.0%	4 0.1%	90.8% 9.2%
9	10 0.2%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	1 0.0%	12 0.3%	6 0.1%	303 6.7%	22 0.5%	7 0.2%	5 0.1%	82.6% 17.4%
10	0 0.0%	0 0.0%	2 0.0%	1 0.0%	7 0.2%	4 0.1%	0 0.0%	1 0.0%	8 0.2%	289 6.4%	0 0.0%	2 0.0%	92.0% 8.0%
11	0 0.0%	5 0.1%	0 0.0%	1 0.0%	1 0.0%	0 0.0%	30 0.7%	3 0.1%	12 0.3%	14 0.3%	348 7.7%	5 0.1%	83.1% 16.9%
12	0 0.0%	0 0.0%	1 0.0%	4 0.1%	0 0.0%	5 0.1%	29 0.6%	16 0.4%	17 0.4%	2 0.0%	7 0.2%	352 7.8%	81.3% 18.7%
	91.2% 8.8%	94.7% 5.3%	88.8% 11.2%	83.3% 16.7%	87.6% 12.4%	81.2% 18.8%	89.1% 10.9%	81.6% 18.4%	80.8% 19.2%	87.1% 12.9%	82.8% 17.2%	83.9% 16.1%	87.7% 12.3%
	1	2	3	4	5	6	7	8	9	10	11	12	

Figura C.13: Matriz de confusão - 2 camadas - 30 neurónios - Peso acima.

Classe alvo	1	318 7.1%	4 0.1%	8 0.2%	2 0.0%	0 0.0%	0 0.0%	0 0.0%	4 0.1%	5 0.1%	4 0.1%	0 0.0%	0 0.0%	32.2%	7.8%
	2	2 0.0%	368 8.2%	0 0.0%	5 0.1%	10 0.2%	2 0.0%	0 0.0%	2 0.0%	6 0.1%	0 0.0%	1 0.0%	0 0.0%	32.9%	7.1%
	3	26 0.6%	1 0.0%	336 7.5%	10 0.2%	0 0.0%	1 0.0%	6 0.1%	0 0.0%	0 0.0%	1 0.0%	5 0.1%	7 0.2%	35.5%	14.5%
	4	0 0.0%	0 0.0%	10 0.2%	350 7.8%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	3 0.1%	5 0.1%	1 0.0%	34.6%	5.4%
	5	0 0.0%	2 0.0%	0 0.0%	3 0.1%	352 7.8%	2 0.0%	9 0.2%	0 0.0%	0 0.0%	8 0.2%	7 0.2%	0 0.0%	31.9%	8.1%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	320 7.1%	3 0.1%	10 0.2%	17 0.4%	10 0.2%	5 0.1%	16 0.4%	34.0%	16.0%
	7	9 0.2%	0 0.0%	14 0.3%	3 0.1%	1 0.0%	22 0.5%	310 6.9%	10 0.2%	10 0.2%	9 0.2%	2 0.0%	30 0.7%	73.8%	26.2%
	8	5 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 0.3%	4 0.1%	332 7.4%	1 0.0%	0 0.0%	0 0.0%	9 0.2%	31.5%	8.5%
	9	15 0.3%	0 0.0%	1 0.0%	1 0.0%	0 0.0%	0 0.0%	5 0.1%	2 0.0%	310 6.9%	3 0.1%	4 0.1%	8 0.2%	38.8%	11.2%
	10	0 0.0%	0 0.0%	5 0.1%	0 0.0%	6 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	312 6.9%	0 0.0%	0 0.0%	36.6%	3.4%
	11	0 0.0%	0 0.0%	0 0.0%	1 0.0%	6 0.1%	0 0.0%	22 0.5%	4 0.1%	2 0.0%	10 0.2%	345 7.7%	4 0.1%	37.6%	12.4%
	12	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	16 0.4%	16 0.4%	10 0.2%	24 0.5%	15 0.3%	1 0.0%	300 6.7%	78.3%	21.7%
		84.8%	88.1%	89.6%	83.3%	83.9%	85.3%	82.7%	88.5%	82.7%	83.2%	82.0%	80.0%	87.8%	
		15.2%	1.9%	10.4%	6.7%	6.1%	14.7%	7.3%	1.5%	7.3%	6.8%	8.0%	20.0%	12.2%	
		1	2	3	4	5	6	7	8	9	10	11	12		
		Classe Obtida													

Figura C.14: Matriz de confusão - 3 camadas - 30 neurónios - Peso acima.